



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Sistemas

**Sistema inteligente para la predicción del precio diario
de las acciones mineras en la Bolsa de New York
usando un modelo híbrido de redes neuronales y
máquina de soporte vectorial de regresión**

TESIS

Para optar el Título Profesional de Ingeniero de Sistemas

AUTOR

Jessica Gabriela HUILLCA ESPILLICO

Renzo Miguel QUISPE ALVAREZ

ASESOR

Dr. David Santos MAURICIO SÁNCHEZ

Lima, Perú

2019



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Huillca, J. & Quispe, R. (2019). *Sistema inteligente para la predicción del precio diario de las acciones mineras en la Bolsa de New York usando un modelo híbrido de redes neuronales y máquina de soporte vectorial de regresión*. [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Escuela Profesional de Ingeniería de Sistemas]. Repositorio institucional Cybertesis UNMSM.



Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América

Vicerrectorado de Investigación y Posgrado
Dirección General de Biblioteca y Publicaciones

Dirección del Sistema de Bibliotecas y Biblioteca Central

"Año de la lucha contra la corrupción y la impunidad"



Hoja de metadatos complementarios

Código ORCID del autor (dato opcional): No tengo

Código ORCID del asesor o asesores (dato obligatorio): <https://orcid.org/0000-0001-9262-626X>

DNI del autor: 47905774

Grupo de investigación: No pertenece

Institución que financia parcial o totalmente la investigación: Autofinanciado

Ubicación geográfica donde se desarrolló la investigación. Debe incluir localidades y/o coordenadas geográficas:

Biblioteca de la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional Mayor de San Marcos – Lima, Lima, Lima, Perú.

Coordenadas: -12.053348, -77.085139

Año o rango de años que la investigación abarcó: 2016 - 2019



Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América

Vicerrectorado de Investigación y Posgrado
Dirección General de Biblioteca y Publicaciones

Dirección del Sistema de Bibliotecas y Biblioteca Central

"Año de la lucha contra la corrupción y la impunidad"



Hoja de metadatos complementarios

Código ORCID del autor (dato opcional): No tengo

Código ORCID del asesor o asesores (dato obligatorio): <https://orcid.org/0000-0001-9262-626X>

DNI del autor: 48736663

Grupo de investigación: No pertenece

Institución que financia parcial o totalmente la investigación: Autofinanciado

Ubicación geográfica donde se desarrolló la investigación. Debe incluir localidades y/o coordenadas geográficas:

Biblioteca de la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional Mayor de San Marcos – Lima, Lima, Lima, Perú.

Coordenadas: -12.053348, -77.085139

Año o rango de años que la investigación abarcó: 2016 - 2019



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
FACULTAD DE INGENIERIA DE SISTEMAS E INFORMATICA
Escuela Profesional de Ingeniería de Sistemas

Acta de Sustentación de Tesis

Siendo las 16:05 horas del día 19 de agosto del año 2019 se reunieron los docentes designados como miembros de Jurado de Tesis, presidido por el Dr. Hugo Froilán Vega Huerta (Presidente), el Mg. Juan Gamarra Moreno (Miembro) y el Dr. David Santos Mauricio Sánchez (Miembro Asesor) para la sustentación de la Tesis Intitulada: **"SISTEMA INTELIGENTE PARA LA PREDICCIÓN DEL PRECIO DIARIO DE LAS ACCIONES MINERAS EN LA BOLSA DE VALORES DE NEW YORK USANDO UN MODELO HÍBRIDO DE REDES NEURONALES Y MÁQUINA DE SOPORTE VECTORIAL DE REGRESIÓN"**, de la Bachiller: **Jessica Gabriela Huilca Espillico**; para obtener el Título Profesional de Ingeniero de Sistemas.

Acto seguido de la exposición de la Tesis, el Presidente invitó a la Bachiller a dar las respuestas a las preguntas establecidas por los Miembros del Jurado.

La Bachiller, en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez a las observaciones y preguntas formuladas por los señores miembros del Jurado.

Finalmente habiéndose efectuado la calificación correspondiente por los miembros del Jurado, la Bachiller obtuvo la nota de.....19..... (En letras).....Diecinueve.....

A continuación el Presidente del Jurado Dr. Hugo Froilán Vega Huerta, declara a la Bachiller, **Ingeniera de Sistemas**.

Siendo las 16:55 horas, se levantó la sesión.

.....
Presidente
Dr. Hugo Froilán Vega Huerta

.....
Miembro
Mg. Juan Gamarra Moreno

.....
Miembro Asesor
Dr. David Santos Mauricio Sánchez



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
FACULTAD DE INGENIERIA DE SISTEMAS E INFORMATICA
Escuela Profesional de Ingeniería de Sistemas

Acta de Sustentación de Tesis

Siendo las 18:05 horas del día 19 de agosto del año 2019 se reunieron los docentes designados como miembros de Jurado de Tesis, presidido por el Dr. Hugo Froilán Vega Huerta (Presidente), el Mg. Juan Gamarra Moreno (Miembro) y el Dr. David Santos Mauricio Sánchez (Miembro Asesor) para la sustentación de la Tesis Intitulada: **“SISTEMA INTELIGENTE PARA LA PREDICCIÓN DEL PRECIO DIARIO DE LAS ACCIONES MINERAS EN LA BOLSA DE NEW YORK USANDO UN MODELO HÍBRIDO DE REDES NEURONALES Y MÁQUINA DE SOPORTE VECTORIAL DE REGRESIÓN”**, del Bachiller: **Renzo Miguel Quispe Alvarez** para obtener el Título Profesional de Ingeniero de Sistemas.

Acto seguido de la exposición de la Tesis, el Presidente invitó al Bachiller a dar las respuestas a las preguntas establecidas por los Miembros del Jurado.

El Bachiller, en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez a las observaciones y preguntas formuladas por los señores miembros del Jurado.

Finalmente habiéndose efectuado la calificación correspondiente por los miembros del Jurado, el Bachiller obtuvo la nota de 19 (DIECINUEVE)

A continuación el Presidente del Jurado Dr. Hugo Froilán Vega Huerta, declara al Bachiller, **Ingeniero de Sistemas**.

Siendo las 18.55 horas, se levantó la sesión.

.....
Presidente
Dr. Hugo Froilán Vega Huerta

.....
Miembro
Mg. Juan Gamarra Moreno

.....
Miembro Asesor
Dr. David Santos Mauricio Sánchez



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú, DECANA DE AMÉRICA
FACULTAD DE INGENIERIA DE SISTEMAS E INFORMATICA
Escuela Profesional de Ingeniería de Sistemas

INFORME DE EVALUACIÓN DE ORIGINALIDAD

1. Facultad de Ingeniería de Sistemas e Informática
2. Escuela Profesional de Ingeniería de Sistemas
3. Autoridad académica que emite el informe de originalidad
Director de la EPIS
4. Apellidos y Nombres de la autoridad académica
Mg. De la Cruz Vélez de Villa, Percy Edwin
5. Operador del programa informático de similitudes
Mg. De la Cruz Vélez de Villa, Percy Edwin
6. Documento evaluado
Título de pregrado "Sistema Inteligente para la predicción del precio diario de las acciones mineras en la bolsa de valores de New York usando un modelo híbrido de redes neuronales y máquina de soporte vectorial de regresión"
7. Autor del documento
Bach. Huilca Espillico, Jessica Gabriela
8. Fecha de recepción del documento 19/08/2019
9. Fecha de aplicación del programa informático de similitudes 20/08/2019
10. Software utilizado
 - Turnitin
11. Configuración del programa detector de similitudes
 - Excluye textos entrecomillados
 - Excluye bibliografía
 - Excluye cadenas menores a 40 palabras
12. Porcentaje de similitudes según programa detector de similitudes 08 (ocho) %
13. Fuentes originales de las similitudes encontradas
Se adjunta en el anexo 1
14. Observaciones
15. Calificación de originalidad
 - Documento cumple criterios de originalidad, sin observaciones ☒
 - Documento cumple criterios de originalidad, con observaciones ☐
 - Documento no cumple criterios de originalidad ☐
16. Fecha de informe 21/08/2019

Firma de evaluador





UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú, DECANA DE AMÉRICA
FACULTAD DE INGENIERIA DE SISTEMAS E INFORMATICA
Escuela Profesional de Ingeniería de Sistemas

INFORME DE EVALUACIÓN DE ORIGINALIDAD

1. Facultad de Ingeniería de Sistemas e Informática
2. Escuela Profesional de Ingeniería de Sistemas
3. Autoridad académica que emite el informe de originalidad
Director de la EPIS
4. Apellidos y Nombres de la autoridad académica
Mg. De la Cruz Vélez de Villa, Percy Edwin
5. Operador del programa informático de similitudes
Mg. De la Cruz Vélez de Villa, Percy Edwin
6. Documento evaluado
Título de pregrado "Sistema Inteligente para la predicción del precio diario de las acciones mineras en la bolsa de valores de New York usando un modelo híbrido de redes neuronales y máquina de soporte vectorial de regresión"
7. Autor del documento
Bach. Quispe Álvarez, Renzo Miguel
8. Fecha de recepción del documento 19/08/2019
9. Fecha de aplicación del programa informático de similitudes 20/08/2019
10. Software utilizado
 - Turnitin
11. Configuración del programa detector de similitudes
 - Excluye textos entrecomillados
 - Excluye bibliografía
 - Excluye cadenas menores a 40 palabras
12. Porcentaje de similitudes según programa detector de similitudes 08 (ocho) %
13. Fuentes originales de las similitudes encontradas
Se adjunta en el anexo 1
14. Observaciones
15. Calificación de originalidad
 - Documento cumple criterios de originalidad, sin observaciones ☒
 - Documento cumple criterios de originalidad, con observaciones ☐
 - Documento no cumple criterios de originalidad ☐
16. Fecha de informe 21/08/2019


Firma de evaluador

Agradecimientos

A nuestros padres y hermanos por el apoyo a lo largo de la carrera y por los ánimos brindados a lo largo de todo el desarrollo de la tesis.

Al Dr. David Mauricio por su dedicación brindada para que este trabajo concluya con éxito.

A todas aquellas personas que indirectamente nos ayudaron a cumplir este trabajo y que constituyen un invaluable apoyo.

Dedicatoria

Este trabajo está dedicado a nuestras familias, amigos, que siempre han mantenido la esperanza y confianza en nuestra capacidad de superación.

Abstract

Predict the share price is a very important issue in the financial world, because it can generate an investment strategy and make a lot of profits. The behavior of equity prices follows a very complex distribution, being affected by internal factors of the companies, such as managerial decisions, and also by external factors, like the state of the market at any given time. The mining sector is considered one of the most volatile sectors in the stock exchange, and frequently attracts riskier investors who want to make quick gains; however, no studies have been found that have focused on this sector.

The accuracy of the machine learning models depends on the correct choice of variables and techniques to be used, as well as on the pre-processing that is performed to the data before being entered into the model, this is why in the present work a survey was made to investment experts in the stock exchange on variables that influence the behavior of a mining stock, consequently variables such as the price of metals, price of indices and price of the dollar were identified; which, together with the fundamental and technical variables, participated in the selection of variables by calculating the Pearson correlation coefficient in each of them.

The resulting variables were later entered into the proposed hybrid model, where the outputs of each of the machine learning techniques used (artificial neural networks, vector regression support machines and radial base neural network) were part of the input to an artificial neural network, considered as the main technique because it achieved the best results in the experimental phase.

To validate the system was considered the dataset of Buenaventura, Southern Copper, Fortuna Silver Mines, Barrick Gold Corporation and BHP Billiton Limited; which achieved a MAPE of 1.666, 1.470, 1.375, 2.567 and 0.998 respectively, and an average error of 1.615%, which shows a large improvement over the 5.4% error obtained in the nearest sector (oil).

Resumen

Predecir el precio de una acción es un tema muy importante en el mundo financiero, debido a que mediante ella se puede generar una estrategia de inversión y obtener muchas ganancias. El comportamiento de los precios de las acciones sigue una distribución muy compleja, siendo afectadas por factores internos de las compañías, tales como decisiones gerenciales, y también por factores externos, como el estado del mercado en un momento dado. El sector minero es considerado uno de los sectores más volátiles dentro de la bolsa, y frecuentemente atrae a los inversionistas más arriesgados que desean obtener rápidas ganancias; sin embargo no se han encontrado estudios que se hayan enfocado en este sector.

La precisión de los modelos de machine learning dependen de la correcta elección de las variables y técnicas a utilizar, así como también del pre procesamiento que se realice a la data antes de ser ingresada al modelo, es por esto que en el presente trabajo se realizó una encuesta a expertos de inversión en la bolsa de valores sobre las variables influyentes en el comportamiento de una acción minera, producto de ello se identificaron variables como el precio de los metales, precio de los índices y precio del dólar; las cuales, junto a las variables fundamentales y técnicas, participaron en la selección de variables mediante el cálculo del coeficiente de correlación de Pearson en cada una de ellas. Las variables resultantes fueron ingresadas posteriormente al modelo híbrido propuesto, donde las salidas de cada una de las técnicas de machine learning utilizadas (redes neuronales artificiales, máquinas de soporte vectorial para regresión y red neuronal de base radial) formaban parte de la entrada hacia una red neuronal artificial, considerada como técnica principal debido a que alcanzaba los mejores resultados en la fase experimental.

Para validar el sistema se consideró el dataset de las empresas Buenaventura, Southern Copper, Fortuna Silver Mines, Barrick Gold Corporation y BHP Billiton Limited; que alcanzaron un MAPE de 1.666, 1.470, 1.375, 2.567 y 0.998 respectivamente, y un promedio de error de 1.615%, lo que demuestra una gran mejora con respecto al 5.4% de error obtenido en el sector más cercano (petrolero).

Tabla de contenido

1	Capítulo 1. Introducción.....	12
1.1	Antecedentes.....	12
1.2	Problemática	14
1.3	Importancia del problema.....	14
1.4	Objetivo	19
1.4.1	Objetivo general	19
1.4.2	Objetivos específicos.....	19
2	Capítulo 2. Revisión de los métodos de inteligencia artificial para predecir el precio de las acciones	20
2.1	Planificación	20
2.2	Proceso.....	22
2.3	Datos estadísticos	26
2.4	Resultado	28
3	Capítulo 3. Revisión de las técnicas utilizadas para la predicción del precio de las acciones.....	38
3.1	Técnica estándar	38
3.2	Técnicas Específicas.....	40
3.2.1	Red Neuronal de función de base radial (RBFNN).....	40
3.2.2	SVM para Regresión (SVR).....	42
3.2.3	Redes Neuronales Artificiales	46
4	Capítulo 4. Modelo de minería de datos para la predicción de las acciones en la bolsa de valores	51
4.1	Esquema general.....	51
4.2	Etapas 1: Selección de datos	53
4.3	Etapas 2: Pre-procesamiento	54
4.4	Etapas 3: Transformación	54

4.5	Etapa 4: Minería de Datos	70
5	Capítulo 5. Software para la predicción del precio diario de una acción basado en RNN y SVR.....	74
5.1	Descripción de roles del sistema	74
5.2	Especificación CUS.....	75
5.2.1	CUS-Authenticación	75
5.2.2	Tratamiento de datos	76
5.2.3	Entrenamiento Simple	78
5.2.4	Entrenamiento Híbrido	80
5.2.5	Validación Simple	82
5.2.6	Validación Híbrido	84
5.2.7	Predecir Precio	86
5.2.8	Log out	87
5.3	Diagrama de Arquitectura	88
5.4	Diagrama de Base de datos.....	88
5.5	Diagrama de componentes.....	89
6	Capítulo 6. Pruebas y validaciones.....	90
6.1	Conjunto de datos de los autores	90
6.2	Pre procesamiento.....	90
6.3	Selección de parámetros	91
6.4	Resultados de Pruebas	93
6.5	Experimentos para evaluar el modelo	96
7	Capítulo 7. Conclusiones y trabajos futuros.....	106
7.1	Conclusiones.....	106
7.2	Trabajos futuros.....	108
8	Referencias	109
9	Anexos.....	114

9.1	Anexo 1: Fórmulas de las variables fundamentales y técnicas	114
9.2	Anexo 2: Formulario y resultado de encuestas.....	120
9.3	Anexo 3: Resultado de pruebas	124
9.3.1	Buenaventura (BVN).....	124
9.3.2	Barrick Gold Corporation (ABX)	129
9.3.3	BHP Billiton Limited (BHP).....	135
9.3.4	Fortuna Silver Mines (FSM)	140
9.3.5	Southern Copper (SCCO):	145

Lista de figuras

<i>Figura 1-1.</i> Mapa de compañías nacionales que cotizan en la bolsa.....	14
<i>Figura 1-2.</i> Rentabilidad anual alcanzada invirtiendo en el año 1802 – 2011	15
<i>Figura 1-3.</i> Comportamiento mensual de Buenaventura.....	16
<i>Figura 1-4.</i> Operaciones mineras recientes de Buenaventura	17
<i>Figura 1-5.</i> Ventas estimadas en los años 2016 y 2017	18
<i>Figura 2-1.</i> Proceso de selección de artículos sobre la predicción del precio de las acciones 22	
<i>Figura 2-2.</i> Número de publicaciones por año	27
<i>Figura 2-3.</i> Documentos por país y territorio.....	27
<i>Figura 3-1.</i> Proceso de Descubrimiento del conocimiento en Base de Datos (KDD)	39
<i>Figura 3-2.</i> Arquitectura de una Red Neuronal RBFNN.....	41
<i>Figura 3-3.</i> SVM para problemas separables	42
<i>Figura 3-4.</i> SVM para problemas no separables	43
<i>Figura 3-5.</i> SVR con margen blanco	44
<i>Figura 3-6.</i> Arquitectura Básica de un perceptrón Multicapa	46
<i>Figura 3-7.</i> Función Sigmoidal.....	48
<i>Figura 4-1.</i> Modelo propuesto.....	52
<i>Figura 4-2.</i> Mercados de la bolsa	58
<i>Figura 4-3.</i> Acciones mineras - expertos.....	58
<i>Figura 4-4.</i> Importancia de los metales	59
<i>Figura 4-5.</i> Importancia del oro.....	60
<i>Figura 4-6</i> Modelo de minera de datos propuesto.....	71
<i>Figura 5-1.</i> Pantalla de login	76
<i>Figura 5-2.</i> Pantalla de tratamiento de datos	78
<i>Figura 5-3.</i> Pantalla de entrenamiento simple.....	80
<i>Figura 5-4.</i> Pantalla de entrenamiento híbrido.	81
<i>Figura 5-5.</i> Pantalla de validación simple.....	84
<i>Figura 5-6.</i> Pantalla de validación híbrido	85
<i>Figura 5-7.</i> Pantalla de predecir precio	87
<i>Figura 5-8.</i> Arquitectura del sistema.....	88
<i>Figura 5-9.</i> Diagrama de datos	88
<i>Figura 5-10.</i> Diagrama de componentes	89
<i>Figura 6-1.</i> Precio predicho vs precio real – Buenaventura	97

<i>Figure 6-2. Precio predicho vs precio real – Fortune Silver Mines.....</i>	<i>99</i>
<i>Figure 6-3. Precio predicho vs precio real – Southern Copper</i>	<i>101</i>
<i>Figura 6-4. Precio predicho vs precio real – Barrick Corporation</i>	<i>103</i>
<i>Figura 6-5. Precio predicho vs precio real - Billiton Limited</i>	<i>105</i>
<i>Figura 9-1. Formulario de preguntas</i>	<i>120</i>
<i>Figura 9-2. Resultado encuesta – primera parte</i>	<i>121</i>
<i>Figura 9-3. Resultado encuesta – segunda parte</i>	<i>122</i>
<i>Figura 9-4. Resultado encuesta – tercera parte</i>	<i>123</i>

Lista de tablas

Tabla 2-1. <i>Lista de 20 artículos seleccionados</i>	23
Tabla 2-2 <i>Factores que influyen en la predicción de precios</i>	28
Tabla 2-3 <i>Técnicas de pre procesamiento para la selección de variables</i>	31
Tabla 2-4 <i>Técnicas de Inteligencia Artificial utilizadas para la predicción de precios</i>	32
Tabla 2-5 <i>Lista de métricas más usadas en la literatura</i>	34
Tabla 2-6. <i>Precisión de las técnicas para la predicción de precios</i>	35
Tabla 4-1. <i>Variables Fundamentales</i>	54
Tabla 4-2. <i>Variables técnicas calculadas a partir de las variables fundamentales</i>	55
Tabla 4-3. <i>Variables indicadas por los expertos</i>	60
Tabla 4-4. <i>Valores de correlación</i>	62
Tabla 6-1 <i>Cantidad de registros de las 5 empresas mineras</i>	90
Tabla 6-2 <i>Resultados de las pruebas con diferentes configuraciones</i>	91
Tabla 6-3 <i>Parámetros de RBFNN</i>	91
Tabla 6-4 <i>Parámetros de SVR</i>	92
Tabla 6-5 <i>Parámetros de la red neuronal</i>	92
Tabla 6-6 <i>Mejor configuración encontrada para los casos de estudio</i>	93
Tabla 6-7 <i>Resultados alcanzados en los casos de estudio</i>	93
Tabla 6-8 <i>Comparación de la evaluación de los resultados de la literatura con el modelo propuesto</i>	95
Tabla 6-9 <i>Precio predicho vs precio real - Buenaventura</i>	96
Tabla 6-10 <i>Precio predicho vs precio real – Fortune Silver Mines</i>	98
Tabla 6-11 <i>Precio predicho vs precio real – Southern Copper</i>	100
Tabla 6-12 <i>Precio predicho vs precio real – Barrick Corporation</i>	101
Tabla 6-13 <i>Precio predicho vs precio real - Billiton Limited</i>	103

1 Capítulo 1. Introducción

1.1 Antecedentes

La bolsa de valores es un mercado donde se comercializan bienes (acciones, bonos y otros títulos), y se caracteriza por tener rentabilidad, liquidez y flexibilidad.

El precio de la bolsa de valores es uno de los indicadores más importantes del crecimiento económico de un país (Gocken, Ozcalici, Boru, & Dosdogru, 2016), es por esto que predecir el comportamiento de un mercado de valores ha sido un área de investigación en curso de mucho interés desde los años noventa. De acuerdo a McNelis (2005) pronosticar simplemente significa entender qué conducen las variables para predecir otras variables.

Por su parte, Hellström y Holmström (1998) identificaron que la tarea de predicción de los precios de las acciones no es fácil. Dentro del ámbito de la ciencia, los investigadores académicos se dividen en dos grupos: los que creen que es posible diseñar mecanismos para predecir el comportamiento del mercado y aquellos que creen en la teoría del mercado eficiente, propuesto por Fama (1970) citado por de Oliveira, Nobre y Zárate (2013) “según el cual el precio de las acciones sigue un comportamiento aleatorio (impredecible)” (p. 7597).

Dentro del grupo que cree que es posible predecir se incluye a Werbos (1994), quien es director de programas de la Fundación Nacional para la Ciencia y expresidente de la Sociedad Internacional de Redes neuronales, en su investigación declaró, teniendo en cuenta una variedad de información, patrones, marcos de tiempo, el pensamiento y el comportamiento de los comerciantes del mercado, que existe la posibilidad de predecir el comercio de los mercados financieros sabiamente.

Esto es contrario a las opiniones de aquellos que se suscriben a la hipótesis del paseo aleatorio (Random Walk Hypothesis - RWH). Esta hipótesis establece que los precios del mercado de valores no se ven afectados por sus precios históricos, sino que vagan de manera aleatoria y por lo tanto no se pueden predecir.

Según Póvoa (2008) citado por de Oliveira, et al. (2013) la hipótesis de los mercados eficientes no puede ser considerada "aceptable". La realidad práctica del mercado, especialmente en relación con la difusión e interpretación de la información, es muy diferente de la hipótesis presentada que asume un mundo ideal. No obstante, afirma que la hipótesis todavía tiene sus méritos, contribuyendo al progreso de los estudios académicos sosteniendo

que el supuesto de que el presente y el futuro pueden repetir el pasado, no puede ser visto como poco realista.

Sabiendo que existen mecanismos para predecir el comportamiento del mercado, y que los datos de las acciones son continuos, el problema fue tratado como un pronóstico de series de tiempo.

Los modelos de series de tiempo financieras expresadas por las teorías financieras han sido la base para la previsión de una serie de datos en el siglo XX. El problema del pronóstico de series de tiempo financieras se ha abordado desde la década de 1980. El objetivo es predecir los mercados financieros y ganar mucho beneficio. Hasta ahora, el pronóstico financiero sigue siendo considerado como uno de las aplicaciones más exigentes del moderno pronóstico de series de tiempo (Tay et al., 2003).

La predicción del mercado de valores es considerado como una tarea desafiante del proceso de predicción de series de tiempo financieras, ya que el mercado de valores es esencialmente dinámico, no lineal, complicado, no paramétrico, y caótico en la naturaleza (Abu-Mostafa & Atiya, 1996). Además, la bolsa se ve afectada por muchos factores económicos macro, tales como eventos políticos, las políticas de las empresas, las condiciones económicas generales, expectativas de los inversores, las opciones de los inversores institucionales, el movimiento de otro mercado de valores, y la psicología de los inversores, etc. (Tan, Quek, & Ng, 2007).

Debido a la capacidad de aprender asignaciones no lineales entre las entradas y salidas, las redes neuronales artificiales (RNA) son uno de los métodos de aprendizaje de máquinas más populares utilizados para predecir los precios del mercado de valores (Egeli, Ozturan, & Badur, 2003). Esto se puede demostrar en algunos estudios realizados como el de Kohara (2003), quien investigó la predicción de precios de las acciones de Tokio usando RNA y, Hassan y Nath (2005), quienes predijeron los precios de las acciones de Southwest Airlines, una aerolínea de América.

Los estudios más recientes que usan RNA se centran en la mejora del rendimiento de predicción y el desarrollo de nuevas arquitectura de RNA (Guresen, Kayakutlu, & Daim, 2011). Otros estudios más recientes, consideran el uso de vectores de soporte de regresión (SVR), el cual ha demostrado tener mejores resultados que las redes neuronales para este tipo de problema. Además, es importante considerar que muchos de los estudios publicados son enfocados en países como EE.UU y los mercados de valores Europeos, esto es debido a la cantidad e importancia de las empresas que cotizan en estas bolsas.

Es por ello, que para el presente trabajo se ha considerado las acciones mineras más importante del Perú y de EEUU, esto con el fin de obtener mayor atención por parte de las inversiones extranjeras en acciones de empresas peruanas que cotizan en mercados internacionales.

1.2 Problemática

El problema de predicción en la bolsa de valores es la expectativa del valor futuro de los precios diarios de las acciones en la Bolsa de valores de New York y se caracteriza por ser incierto, dinámico y no lineal.

1.3 Importancia del problema

La cantidad de empresas que cotizan en la bolsa de valores a nivel mundial ha ido incrementándose con el pasar del tiempo, lo que ha atraído la atención de una mayor cantidad de inversionistas, quienes tratan de rentabilizar sus capitales comprando y vendiendo acciones dentro de la bolsa. En la Figura 1-1 se puede observar que los países con una mayor cantidad de empresas en la bolsa son: EEUU, China, Japón seguido de Canadá y Alemania; los cuales también son los más interesados en resolver el problema de predicción del precio de una acción.

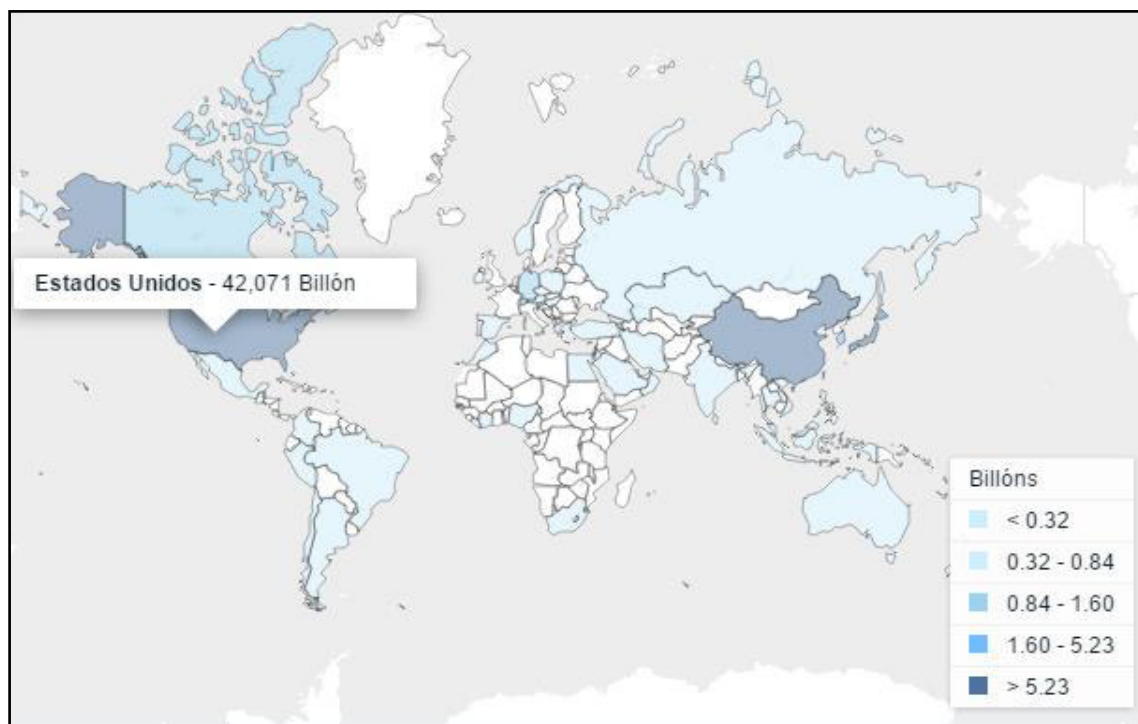


Figura 1-1. Mapa de compañías nacionales que cotizan en la bolsa

Fuente: Banco mundial (2016)

Ahora, ¿por qué elegir invertir en acciones?, en la Figura 1-2 se compara la rentabilidad que se hubiera obtenido invirtiendo 1 dólar en el año 1802 en los diferentes tipos de valores que se comercializan en la bolsa:




Figura 1-2. Rentabilidad anual alcanzada invirtiendo en el año 1802 – 2011

Fuente: Lodeiro (2011)

Como se observa en la Figura 1-2, invertir un dólar en el año 1802 en acciones habría generado 930.550 dólares para el año 2011, esto supone una rentabilidad anual compuesta de aproximadamente 6.7%, muy superior a la siguiente mejor inversión (bonos), los cuales solo hubieran producido una rentabilidad de 3.5% anual.

Entonces, ya habiendo analizado los países con mayor presencia en la bolsa y los tipos de valores con mayor rentabilidad, la pregunta ahora sería: ¿En qué acciones es recomendable invertir?, o ¿qué rubro de acciones es recomendable invertir?, la respuesta depende mucho del tipo de inversión que se quiere hacer, si es a largo, mediano o a corto plazo.

Cuando se trata de inversiones a mediano o largo plazo se busca un crecimiento continuo, donde se pueda ver los beneficios de la inversión a partir de varios años o meses, con un menor riesgo de inversión, para este tipo de inversores, lo mejor es invertir en índices de empresas. Un índice es un conglomerado de varias acciones de empresas de un mismo sector y su valor, por lo general, es el promedio simple de cada una de ellas. Estos índices no tienen variaciones tan bruscas debido a que, como son el promedio de varias empresas, debería haber una

variación en un mismo sentido de todas para que se note el cambio en el valor del índice, por lo general estos índices tienen un crecimiento lento en el tiempo y el sector más recomendable para hacer este tipo de inversiones es el sector tecnológico.

Cuando se trata de inversiones a corto plazo, no se busca tener invertido un capital a varios meses, lo que se busca es ver un beneficio rápido para volver a invertir ese dinero ganado. Este tipo de inversores prefiere correr un mayor riesgo de inversión a cambio de obtener ganancias en un menor tiempo, por lo que se buscan acciones volátiles, las cuales, por el mismo sector en el que se encuentran, los precios varían considerablemente en un tiempo corto.

El presente estudio está enfocado a este tipo de inversiones (acciones volátiles), por eso el precio que se va a predecir, es el precio diario de la acción. Analizando la bolsa de EEUU, se observó que uno de los sectores más volátiles y por ende, de mayor riesgo a corto plazo, es el sector minero. Es ahí donde nace el mayor problema financiero, en aquellas acciones volátiles, donde el precio futuro es cada vez más incierto y la cantidad de pérdida también lo es. Analizando el grupo de cinco acciones mineras (Buenaventura, Barrick gold corporation, BHP Billiton limited, Fortuna silver mines, Southern copper), y considerando que Perú es uno de los países mineros más importantes, se halla una de las empresas mineras más importantes, Buenaventura, empresa peruana con la mayor cantidad de derechos en el Perú y con más de 64 años de experiencia en el rubro.

En la Figura 1-3 se muestra el comportamiento de la acción Buenaventura en el periodo de un mes, observamos que el precio ha variado constantemente logrando tener el precio más bajo en este periodo de 11.51 el 27 de Abril del 2017 y el más alto de 12.74 el 17 de mayo del 2017, una diferencia de 1.23 en tan solo un mes.




Figura 1-3. Comportamiento mensual de Buenaventura

Fuente: Yahoo Finance (2017)

Buenaventura es actualmente la empresa más importante del sector minero en Perú, el siguiente gráfico muestra la distribución de metales que Buenaventura opera a lo largo del país.

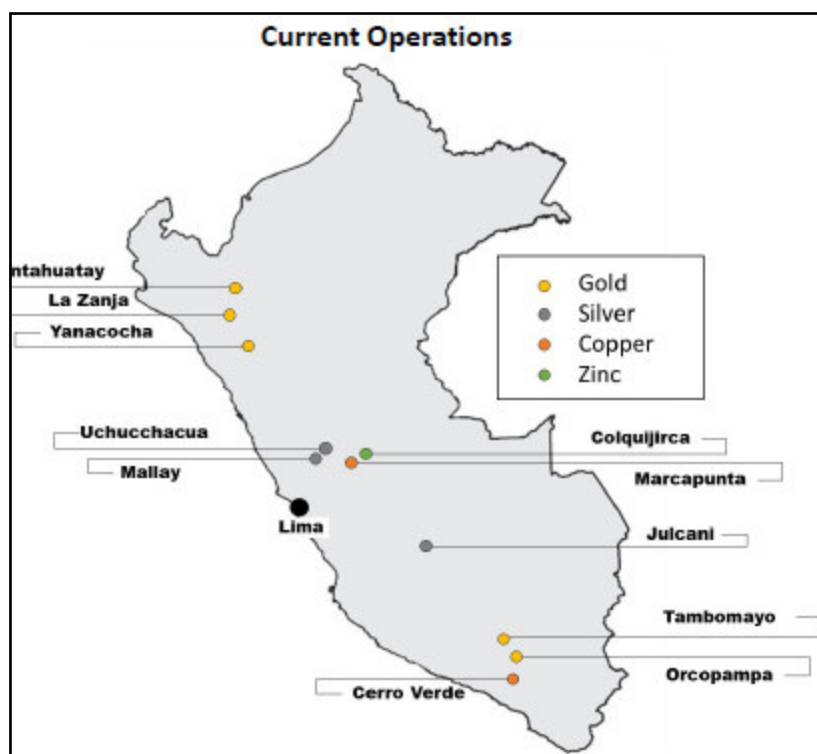


Figura 1-4. Operaciones mineras recientes de Buenaventura

Fuente: (Buenaventura, 2017)

Como se observa en la Figura 1-4, Buenaventura opera en más de 10 yacimientos en todo el Perú, donde la mayor cantidad de metales que comercializa son el oro, plata, cobre y zinc. En la Figura 1-5 se muestra el porcentaje de ventas de cada metal comercializado en los años 2016 y 2017.




Figura 1-5. Ventas estimadas en los años 2016 y 2017

Fuente: elaboración propia

En la Figura 1-5 se observa la variación de las ventas de los metales de Buenaventura del año 2016 a inicios del 2017, ha teniendo una disminución en un 2% para los metales oro y cobre, pero al mismo tiempo hubo un aumento del 2% para la plata y zinc. Es importante mostrar los metales que son comercializados por Buenaventura debido a que, se demostrará en los capítulos siguientes, cómo su variación influye directamente en el precio de sus acciones.

Los analistas financieros y los inversores observan las tendencias del mercado de valores con el fin de realizar operaciones de compra y venta, y obtener rentabilidad financiera de tales transacciones. Ellos analizan los datos de precios históricos y los indicadores económicos para la toma de decisiones. Tales decisiones tienen normalmente el siguiente proceso:

Primero, se selecciona una lista de empresas basándose en su potencial de crecimiento y los fundamentos económicos de rendimiento, para luego examinar los cambios de los precios, por lo que una estrategia de negociación correcta se ejecuta en el momento apropiado. (Assaf, 2011; Francis, 1991; Frank & Norton, 2008; Lima, 2008; Matsura, 2007 citados por de Oliveira, et al., 2013, p. 7596)

Tener un cálculo acertado sobre los precios futuros de las acciones trae consigo las siguientes ventajas:

- Generar beneficios para los inversores. Debido a la complejidad de los datos del mercado de valores y el desarrollo de modelos eficientes para predecir, debido a que es muy difícil (Yakup y Melek, 2011).

- Contribuir al desarrollo de estrategias efectivas para operaciones bursátiles y atraer mucho interés en la incorporación de variables de series históricas en los modelos matemáticos o los algoritmos informáticos con el fin de producir estimaciones de las fluctuaciones de los precios esperados. (de Oliveira, et al., 2013)

1.4 Objetivo

1.4.1 Objetivo general

Desarrollar un Sistema Inteligente para mejorar la predicción del precio diario de las acciones enfocados en el sector minero en la Bolsa de valores de New York a través de técnicas de machine learning.

1.4.2 Objetivos específicos

- Identificar los factores que influyen en la predicción de los precios de las acciones mineras en la bolsa de valores de New York.
- Identificar la técnica más adecuada para seleccionar las variables más influyentes en la predicción de precios de acciones.
- Identificar las técnicas de machine learning propuestas para resolver adecuadamente el problema de predicción de precios de una acción
- Identificar y seleccionar las métricas adecuadas para medir la precisión de la predicción.

2 Capítulo 2. Revisión de los métodos de inteligencia artificial para predecir el precio de las acciones

El presente capítulo muestra una visión detallada del método a seguir para la investigación de la predicción de los precios de las acciones. Dicha investigación se separa en 3 etapas, la primera, denominada Planificación, muestra las características que ayudaron a delimitar el problema, para luego formular preguntas de investigación. En la segunda etapa llamada Proceso, se muestra el detalle de los artículos seleccionados de acuerdo a los criterios de inclusión y exclusión, adicional a ello, se muestran gráficos estadísticos que resumen las publicaciones por año, país y revista. Por último, se tiene la etapa titulada Resultados, donde se responden a las preguntas formuladas en la primera etapa.

2.1 Planificación

Para lograr el objetivo de la presente investigación, se plantean las siguientes preguntas:

Q1: ¿Qué factores han sido los adecuados para ser considerados en la predicción de los precios de las acciones en la Bolsa de Valores?

Q2: ¿Qué técnicas han sido utilizadas para seleccionar las variables más representativas en la predicción de los precios de las acciones en la Bolsa de Valores?

Q3: ¿Qué técnicas de inteligencia artificial han sido propuestas para resolver la predicción de los precios de las acciones en la Bolsa de Valores?

Q4: ¿Qué modelo es el más adecuado para la predicción del precio de las acciones en la bolsa de Valores?

El área de estudio de la presente investigación según la taxonomía de ACM es el siguiente:

- i. Computing methodologies
- ii. Machine Learning
- iii. Machine learning approaches

Las limitaciones que se tienen para realizar la investigación en base al problema, sector y técnica son:

- Las técnicas a utilizar deben pertenecer al área de machine learning.
- Las predicciones que se realizarán serán predicciones diarias de los precios de cierre de una acción en la bolsa de valores.

- El sector enfocado para la predicción será el sector minero, debido a que estas acciones son consideradas dentro del grupo de acciones más volátiles.
- Se trabajará con los datos de las acciones de la bolsa de valores de New York debido a que contiene el mayor volumen de acciones cotizadas a nivel mundial.

Las fuentes que se utilizaron para la revisión de los métodos de inteligencia artificial son:

- Journal con factor de impacto ISI o SJR.
- Bancos: Science Direct, ACM, IEEE, Springer, DOAJ, Taylor and Francis, Emerald.

Los principales motores de búsqueda utilizados para la recolección de los artículos son:

- Google Scholar
- Scopus

Entre los descriptores utilizados para el método de búsqueda se encontraron:

“Prediction”

“Stock Market”

“Daily Price”

“Stock Prediction”

“Financial forecasting”

“Financial time series (FTS)”

“Prediction” and “Daily Price”

“Prediction” and “Stock Price”

“Prediction” and “Stock Market”

“Prediction” and “Daily Price” and “Stock market”

“Stock Price” and “Financial forecasting”

Para los criterios de inclusión se tomaron en cuenta algunas consideraciones relacionadas a los artículos como sigue:

Los artículos incluyen métodos o modelos de predicción, los cuales son probados para resolver el problema de predicción de precios.

Los artículos resuelven el problema en base al uso de técnicas de machine learning.

Los criterios de exclusión que se tomaron en cuenta son:

- Los artículos tienen que poseer factor de impacto SJR o ISI.
- Los artículos seleccionados deben encontrarse dentro del periodo de enero del 2010 a diciembre del 2016.

2.2 Proceso

Luego de aplicar los descriptores de búsqueda en los bancos seleccionados, se obtuvieron 159 artículos comprendidos entre los años 2010 - 2016, seguidamente se aplica los criterios de exclusión, el primer criterio a aplicar es en base al factor de impacto que deben tener las revistas a las cuales pertenecen los artículos, aplicando este criterio se obtienen 52 artículos, por último se seleccionan 20 artículos, los cuales muestran mejores resultados al momento de aplicar las técnicas de machine learning para la predicción de los precios de las acciones utilizando técnicas de inteligencia artificial.

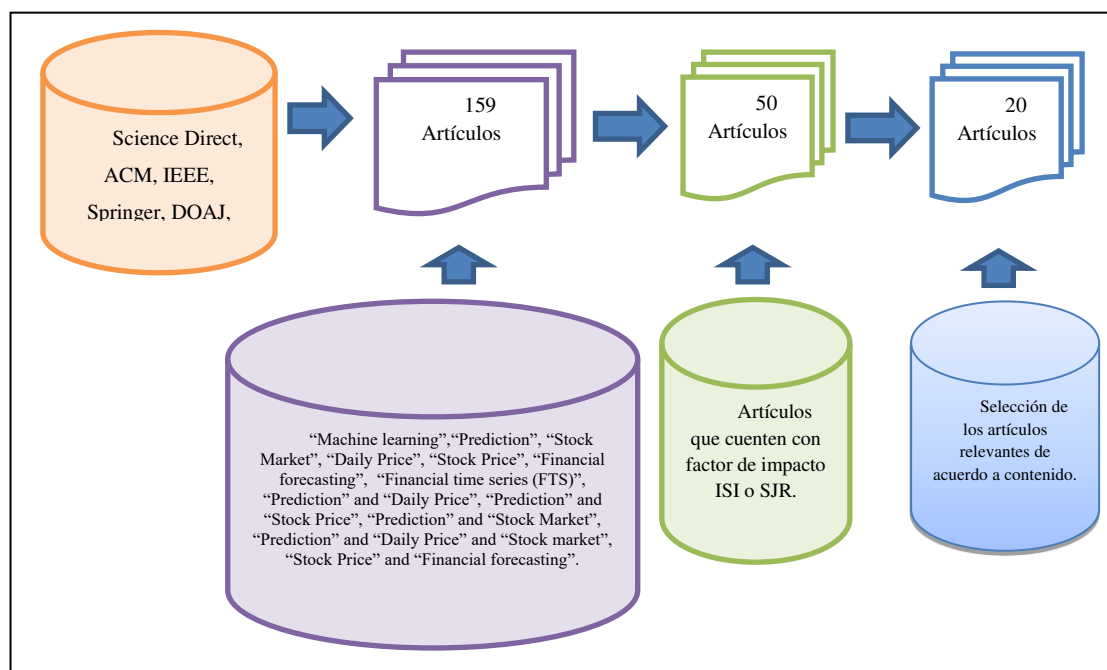


Figura 2-1. Proceso de selección de artículos sobre la predicción del precio de las acciones

Fuente: elaboración propia

En base a la búsqueda realizada, se seleccionaron 20 artículos, los cuales se presentan en la siguiente tabla y son estudiados en la presente tesis.

Tabla 2-1. *Lista de 20 artículos seleccionados*

Título del artículo	Journal / Conferencia	Factor de Impacto SJR	Autor(es)
Integrating independent component analysis-based denoising scheme with neural network for stock price prediction.	Expert Systems with Applications	2.254	Lu (2010)
An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the prediction of stock market return: The case of the Istanbul Stock Exchange.	Expert Systems with Applications	2.254	Boyacioglu y Avci (2010)
A hybrid procedure for stock price prediction by integrating self-organizing map and genetic programming.	Expert Systems with Applications	2.254	Hsu (2011)
A hybrid model based on adaptive-network-based fuzzy inference system to forecast Taiwan stock market.	Expert Systems with Applications	2.254	Wei, Chen y Ho (2011)
Using artificial neural network models in stock market index prediction.	Expert Systems with Applications	2.254	Guresen, Kayakutlu y Daim (2011)
A comparative study of artificial neural networks, and decision trees for digital game content stocks price prediction.	Expert Systems with Applications	2.254	Chang (2011)
Combining nonlinear independent component analysis and neural network for the prediction of Asian stock market indexes.	Expert Systems with Applications	2.254	Dai, Wuc y Lu (2012)

Integration of nonlinear independent component analysis and support vector regression for stock price forecasting.	Neurocomputing	1.202	Kao, Chiu, Lu y Yang (2013)
--	----------------	-------	-----------------------------

Fuente: elaboración propia

Tabla 2.1. (Continuación)

Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index-Case study of PETR4, Petrobras, Brazil.	Expert Systems with Applications	2.254	de Oliveira, et al. (2013)
A Bayesian regularized artificial neural network for stock market forecasting.	Expert Systems with Applications	2.254	Ticknor (2013)
Stock closing price forecasting using ensembles of constructive neural networks	Brazilian Conference on Intelligent Systems (BRACIS)	0.206	Joao, Guidoni, Bertini, Nicoletti y Artero (2014)
Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting.	Knowledge-Based Systems	2.92	Hadavandi, Shavandi y Ghanbari (2015)
Maximum-and-minimum-stock-price-forecasting-of-Brazilian-power-distribution-companies-based-on-artificial-neural-networks.	Applied Soft Computing	1.763	Laboissiere, Fernandes y Lage (2015)
Integrating Metaheuristics and artificial neural networks for improved stock price prediction.	Expert Systems with Applications	2.254	Gocken, et al. (2016)
Improving Artificial Neural Network based Stock Forecasting using Fourier De-Noising and Hodrick-Prescott Filter.	International Conference on Information Communications and Signal Processing (ICICS)	0.1	Mitra y Wang (2015)

Polynomial based functional link artificial recurrent neural network adaptive system for predicting Indian stocks.	International Journal of Computational Intelligence Systems	0.366	Bebarta, Biswal y Dash (2015)
--	---	-------	-------------------------------

Fuente: elaboración propia

Tabla 2.1. (*Continuación*)

A Stock Market Forecasting Model Combining Two-Directional Two-Dimensional Principal Component Analysis and Radial Basis Function Neural Network.	PLOS One	1.395	Guo, Wang, Yang y Miller (2015)
Improved v-Support Vector Regression Model Based on Variable Selection and Brain Storm Optimization for Stock Price Forecasting.	Applied Soft Computing	1.763	Wang, Hou, Wang, Shen (2016)
A Typical Framework for Forecasting and Trading Time Series Data Using Functional Link Artificial Neural Network.	International Journal of Engineering and Technology (IJET)	0.177	Bebarta, y Rout (2016)
Optimizing Stock Market Price Prediction using a Hybrid Approach Based on HP Filter and Support Vector Regression	International Colloquium on Information Science and Technology (CIST)	0.104	Ouahilal, Mohajir, Chahhou y Eddine (2016)

Fuente: elaboración propia

2.3 Datos estadísticos

En esta sección se muestran los gráficos que describen la evolución de las publicaciones relacionadas al problema en el tiempo.




Figura 2-2. Número de publicaciones por año

Fuente: SCOPUS

Los primeros artículos acerca del estudio de las predicciones de los precios de la bolsa de valores se empezaron a publicar a partir del año 1990 y se ve que hay un interés creciente por abordar el problema debido a las exorbitantes cantidades de dinero que se negocian en los mercados financieros.

Como se observa, entre el 2009 y 2014 son los años en que más publicaciones de artículos ha habido relacionados al tema de estudio.




Figura 2-3. Documentos por país y territorio

Fuente: SCOPUS

En la Figura 2-3 se puede observar que China es el país que más publicaciones realiza acerca de las predicciones de los precios de las acciones en la bolsa de valores, seguido de India.

Se observa también que dentro del grupo de países que realizan publicaciones, Singapur es el que menos documentos ha publicado con respecto a este tema.

2.4 Resultado

En esta sección se responde a cada una de las preguntas de investigación planteadas en la sección 2.1.

Pregunta Q1: ¿Qué factores han sido los adecuados para ser considerados en la predicción de los precios de las acciones en la bolsa de Valores?

De acuerdo a los estudios dados en los artículos seleccionados se obtiene el siguiente cuadro.

Tabla 2-2 *Factores que influyen en la predicción de precios*

Factor	Descripción	Referencias
Precio de apertura	Es el primer precio de una acción determinada en un diario de negociación.	de Oliveira, et al. (2013), Hadavandi, et al. (2015), Lu (2010), Laboissiere et al. (2015), Wang, et al. (2016), Mitra y Wang (2015), Ouahilal, et al. (2016), Joao, et al. (2014), Ticknor (2013).
Precio de cierre	Es el precio de la última transacción dada en el final de un diario de negociación.	de Oliveira, et al. (2013), Hadavandi et al (2015), Gocken, et al (2016), Kao, et al. (2013), Wang et al (2016), Mitra y Wang (2015), Ouahilal et al. (2016), Joao et al. (2014), Ticknor et al. (2013)
Precio mínimo	Es el precio más bajo que se pagó por una acción en un diario de negociación.	de Oliveira, et al. (2013), Hadavandi et al (2015), Gocken, et al (2016), Wang et al (2016), Mitra y Wang (2015), Ouahilal et al. (2016), Joao, et al. (2014), Ticknor (2013)
Precio máximo	Es el precio más alto que se pagó por una acción en un diario de negociación.	de Oliveira, et al. (2013), Hadavandi et al (2015), Gocken, et al (2016), Wang et al (2016), Mitra y Wang (2015), Ouahilal, et al. (2016), Joao et al. (2014), Ticknor et al. (2013)
Volumen	Son la cantidad de transacciones realizadas para una acción en un día.	de Oliveira, et al. (2013), Lu (2010), Wang et al (2016), Ouahilal et al. (2016), Ticknor (2013)
Precio de cierre del día previo	Es el precio de la última transacción realizada un día previo al actual.	Dai et al (2012), Lu (2010), Chang (2011), Gocken, et al (2016), Laboissiere, et al (2015).
Precio máximo del día previo	Es el precio máximo que alcanzo la acción un día previo al actual.	Gocken, et al. (2016) Laboissiere, et al. (2015), Dai, et al (2012), Lu (2010)
Precio mínimo del día previo	Es el precio mínimo que alcanzó la acción un día previo al actual.	Gocken, et al. (2016), Laboissiere, et al. (2015), Dai, et al. (2012), Lu (2010)
Precio de apertura del día anterior	Es el precio de apertura de la acción un día previo al actual.	Laboissiere et al. (2015)
TAPI	Cantidad de peso del índice de precios.	Ticknor (2013)

Precio de cierre del DAX	Es el precio de la última transacción del índice más conocido de la Bolsa alemana.	Boyacioglu y Avci (2010)
Precio de cierre BOVESPA	Es el precio de la última transacción del indicador más importante del mercado de acciones de Brasil	Boyacioglu y Avci (2010)
Precio de cierre DJI	Es el precio de la última transacción, del índice bursátil con acciones más significativas, de todas las industrias en EE.UU.	de Oliveira, et al. (2013), Boyacioglu y Avci (2010)
Acciones finales US	Acciones finales US	de Oliveira, et al. (2013)

Fuente: elaboración propia

Tabla 2-2 (*Continuación*)

Indicador de fuerza relativa (RSI)	Mide la fuerza con la que suben o bajan los precios.	de Oliveira, et al. (2013), Wei, et al. (2011), Wei et al (2013) , Lu (2010), Gocken, et al (2016), Wang et al (2016), Bebart et al (2015), Hsu (2011), Ticknor (2013)
Momentum	Indicador que mide la aceleración y desaceleración en los cambios de los precios entre dos instantes en el tiempo.	de Oliveira, et al. (2013), Gocken, et al (2016), Hsu (2011)
Índices Estocásticos	Indicador que compara el precio de cierre de hoy con precios de días anteriores.	de Oliveira, et al. (2013), Wei, et al (2011), Wei et al (2013), Gocken, et al (2016), Hsu (2011), Ticknor (2013)
Promedios móviles	Indicadores que allanan o suavizan, en mayor o menor medida, la evolución de las cotizaciones.	de Oliveira, et al. (2013), Wei et al (2011), Wei et al (2013), Gocken, et al (2016), Hsu (2011), Ticknor et al. (2013)
Willian R%	Indicador que mide qué tan cerca del máximo o del mínimo han cerrado los precios.	de Oliveira, et al. (2013), Wei et al (2011), Gocken, et al (2016), Hsu (2011), Ticknor (2013)
Balance de volúmenes (OBV)	Indicador que relaciona el volumen con los cambios de precio que han acompañado este volumen.	de Oliveira, et al. (2013)
Banda media de Bollinger	Promedio móvil entre la banda alta y baja de Bollinger.	de Oliveira, et al. (2013), Gocken, et al (2016).
Banda alta de Bollinger	Es la máxima desviación negativa que tiene la banda media.	de Oliveira, et al. (2013), Gocken, et al (2016).
Precio medio	Precio medio en el día de la acción.	Gocken, et al (2016)
Mejor oferta de hace 4 días	Mejor oferta de los últimos 4 días	Laboissiere, et al. (2015)
Promedio móvil ponderado del dólar	Es el promedio ponderado del precio del dólar en un intervalo de 21 días.	Laboissiere, et al. (2015)

Monto	Es el valor nominal del monto de las acciones compradas o vendidas en un día.	Wang, et al. (2016)
BIAS	Mide la manipulación deliberada del precio de una acción.	Wang, et al. (2016), Hsu (2011)
Indicador de cambio del volumen del precio (PVC)	Mide la variación del volumen multiplicado por el precio.	Bebarta, et al. (2015).
Indicador de volumen móvil promedio (MAVI)	Mide la variación del volumen promedio.	Bebarta, et al. (2015).
Relación acumulativa (AR)	Relación acumulativa	Hsu (2011)

Fuente: elaboración propia

Tabla 2-2 (*Continuación*)

MACD	Trabaja como una medida filtrada del derivado del precio de las acciones con respecto al tiempo.	de Oliveira, et al.. (2013), Hsu (2011)
Fecha	Fecha en la que se tomaron los indicadores.	Ouahilal, et al. (2016)
Precio del petróleo Brent	Precio del petróleo Brent	de Oliveira, et al. (2013)
Empleo formal	Empleo formal	de Oliveira, et al. (2013)
Tasa de interés de interés Selic	Tasa de interés de interés Selic	de Oliveira, et al. (2013)
Tasa de interés del CDI	Tasa de interés del promedio diario de los créditos interbancarios diario en Brasil.	de Oliveira, et al. (2013)
Índice de confianza del consumidor	Índice de confianza del consumidor	de Oliveira, et al. (2013)
Índice de expectativas futuras	Índice de expectativas futuras	de Oliveira, et al. (2013)
Índice de materias primas energéticas de Brasil	Índice de materias primas energéticas de Brasil	de Oliveira, et al. (2013)
Variación porcentual del dólar	Variación porcentual del dólar	de Oliveira, et al. (2013)
Participación de los inversores	Participación de los inversores	de Oliveira, et al. (2013)

Indicador de momento de compra / venta (AR)	Es el índice que indica el momento de la compra y venta.	Hsu (2011)
Indicador de la voluntad de compra / venta (BR)	Es un índice que indica el momento de la propensión a la compra y venta	Hsu (2011)
Índice de canal de productos básicos (CCI)	Es una oscilador que mide el posición del precio en relación a este movimiento de medio(BR)	Hsu (2011)
Tasa de cambio (ROC)	Es un indicador técnico que mide la tasa de cambio del precio en relación a periodos anteriores	Wang, et al. (2016), Hsu (2011)
Indicador direccional (DI)	Este indicador representa la fuerza que ha tenido el movimiento de hoy en comparación con el rango verdadero.	Hsu (2011)
Linea psicológica (PSY)	Es un indicador de sentimiento, utilizado para predecir las reversiones a corto plazo del mercado.	Wang et al. (2016), Hsu (2011), , Wei, et al (2011)
Diferencia (DIF)	Diferencia entre el precio de cierre del día actual y el día previo	Wang, et al. (2016)

Fuente: elaboración propia

En la Tabla 2-2 se observa que entre los factores que han sido usados con mayor frecuencia en la predicción del precio de las acciones en la bolsa de valores se encuentran: el precio de apertura, el precio de cierre, el precio máximo y el precio mínimo de una acción; siendo estas, junto con el “volumen”, las variables fundamentales a partir de las cuales son generadas las siguientes variables (técnicas).

Pregunta Q2: ¿Qué técnicas han sido utilizadas para seleccionar las variables más representativas en la predicción de los precios de las acciones en la Bolsa de Valores?

Gran parte del éxito de los modelos revisados en la literatura es debido a la correcta selección de variables de entrada, por lo que diversas técnicas han sido usadas con este fin. La siguiente tabla muestra el resumen de las técnicas de selección de variables que han sido propuestas en la literatura:

Tabla 2-3 *Técnicas de pre procesamiento para la selección de variables*

Técnica	Descripción	Referencia
Heterocedasticidad condicional autorregresiva	Modelo estadístico utilizado para la extracción de características.	Guresen, et al (2011)

generalizada (GARCH)		
Análisis de correlación	Técnica de selección de variables donde los atributos con una alta correlación con respecto a la salida son considerados para la predicción.	Wei, et al (2011); Laboissiere et al (2015); Wang, et al (2016)
Análisis de correlación cruzada	Es una medida entre dos variables, usada para encontrar características relevantes en una variable desconocida por medio de la comparación con otra que sí se conoce.	de Oliveira, et al. (2013)
El análisis de regresión por etapas (SRA)	El método de regresión paso a paso determina el conjunto de factores independientes que determinan más estrechamente a la variable dependiente.	Hadavandi et al (2010)
Análisis de componentes principales (PCA)	Técnica estadística multivariable implementada para reducir la dimensionalidad y extraer rasgos característicos del conjunto de datos original.	Wang et al (2016); Guo, et al. (2015)
Análisis de componentes independientes (ICA)	Técnica de extracción de características para el análisis de componentes independientes.	Lu (2010)
Análisis de componentes independientes no lineales (NLICA)	Técnica de extracción de características para componentes no lineales, usado para convertir las variables de predicción en componentes independientes, que luego serán usados en los métodos de predicción.	Kao, et al. (2013); Dai, et al (2012)
Harmony Search (HS)	Técnica para la selección de los variables, los cuales consisten en evaluar la utilidad de las variables y eliminar los irrelevantes.	Gocken, et al (2016)
Hodrick – Prescott (HP)	Es una herramienta matemática para eliminar componente ciclo de una serie de tiempo a partir de datos sin procesar.	Mitra y Wang (2015); Ouahilal, et al. (2016)

Fuente: elaboración propia

En la Tabla 2-3 se observa que entre las técnicas de pre procesamiento más usadas se encuentra el análisis de correlación con un total de tres referencias.

Pregunta Q3: ¿Qué técnicas de inteligencia artificial han sido propuestas para resolver la predicción de los precios de las acciones en la Bolsa de Valores?

Diversas técnicas de inteligencia artificial han sido usadas en la literatura, a continuación, se presenta la descripción de cada una de ellas y la referencia al paper que la usó.

Tabla 2-4 *Técnicas de Inteligencia Artificial utilizadas para la predicción de precios*

Técnica	Descripción	Referencia
Perceptrón Multicapa		Guresen, et al (2011)

		de Oliveira, et al. (2013)
		Lu (2010)
		Chang (2011)
		Dai, et al. (2012)
		Wei, et al. (2011)
	Red Neuronal que posee tres capas: entrada, oculta y salida; es una de las topologías de redes neuronales más ampliamente implementadas.	Boyacioglu y Avci (2010)
		Gocken, et al. (2016)
		Laboissiere, et al (2015)
		Mitra y Wang (2015)
		Joao, et al. (2014)
ANFIS	Sistema de inferencia difusa	Wei, et al. (2011)
		Kao, et al. (2013)
Support Vector Regression	Basada en SVM, realiza un mapeo no lineal de los datos entrada.	Wang, et al. (2016)
		Ouahilal, et al. (2016)
Red neuronal recurrente	Red Neuronal retroalimentada, en la cual una salida vuelve a ser la entrada para el siguiente caso.	Bebarta, et al. (2015)
FLANN	Red neuronal de una sola capa, en la cual la “no linealidad” es introducida, modificando los parámetros de entrada mediante funciones de bloque.	Bebarta y Rout (2016)
RBFNN	Red neuronal que usa la función de base radial como función de activación.	Guo, et al. (2015)
Self-Organizing Map (SOM)	Red neuronal no supervisada que divide la data de entrada en clúster donde los datos tienen patrones en común.	Hsu (2011)

Fuente: elaboración propia

De la Tabla 2-4, se puede notar que la técnica más utilizada para la predicción del precio de las acciones es la Red neuronal de tipo perceptrón multicapa, tomando en cuenta también que el algoritmo de aprendizaje que utilizan con esta red es el de back-propagation.

Pregunta Q4: ¿Qué modelo es el más adecuado para la predicción del precio de las acciones en la bolsa de Valores?

Para dar respuesta a esta pregunta, primero es necesario conocer las métricas que han sido más utilizadas, para luego comparar los modelos planteados con dichas métricas y establecer los modelos que obtienen mejores resultados. Se presenta la tabla con las métricas más utilizadas en los artículos revisados:

Tabla 2-5 *Lista de métricas más usadas en la literatura.*

Métrica	Descripción	Referencia
MSE	Error cuadrático medio	Wang, et al. (2016), Gocken, et al (2016), Mitra y Wang (2015), Guresen, et al. (2011)
MAE	Promedio de errores absolutos.	Wang et al (2016), Gocken, et al (2016), Laboissiere et al (2015), Hsu (2011)
MAPE	El error absoluto porcentual promedio (MAPE), es la media o promedio de los errores porcentuales absolutos de pronósticos, se utiliza para evaluar el error de predicción.	Wang, et al. (2016), Guo, et al. (2015), Ouahilal, et al. (2016), Bebart, et al. (2015), Gocken, et al. (2016), Mitra y Wang (2015), Bebart y Rout (2016), de Oliveira, et al. (2011), Hsu (2011), Lu (2010), Hadavandi, et al. (2015), Kao, et al (2013), Laboissiere et al (2015), Dai et al (2012), Wei et al (2013)
MAD	Desviación media absoluta	Kao, et al. (2013), Guresen et al (2011), Dai et al (2012)
RMSE	Porcentaje de la raíz del error cuadrático medio.	Guo et al (2015); Gocken, et al (2016); Kao et al (2013); Laboissiere, et al. (2015); Mitra y Wang (2015); de Oliveira, et al. (2013); Hsu (2011); Wei et al (2011); Dai, et al. (2012); Lu (2010)
AE	Error promedio	Joao, et al. (2014)
SD	Desviación estándar	Joao, et al. (2014)

Fuente: elaboración propia

De las métricas mostradas en la Tabla 2-5, se seleccionaron las métricas MAPE y RMSE ya que a que fueron elegidos en mayoría por los autores debido a la precisión en los modelos de regresión principalmente predicción. En base a ello se harán uso de estas dos métricas para comparar los resultados de las técnicas de Inteligencia Artificial.

Tabla 2-6. *Precisión de las técnicas para la predicción de precios*

Modelo	Tipo de Acción	Caso Estudio	MSE	MAPE	RMSE	Referencia	Data Set
HP - SVR	Empresa	Maroc Telecom (IAM)		0.067		Ouahilal, et al. (2016)	01/2004 - 12/2016
PFLARNN	Empresa	IBM		1.382		Bebarta, et al. (2015)	04/2012 - 05/2012
	Empresa	CPFE3		0.8021 / 0.9187	2.3e-5 / 3.3e-5		
ANN	Empresa	CEBR3		0.8553 / 0.9452	1.0e-4 / 5.3e-5	Laboissiere, et al. (2015)	01/2008 - 09/2013
	Empresa	CSRN3		0.6224 / 2.1283	4.5e-5 / 3.0e-4		
	Empresa	MSFT	0.91	0.97	0.95		
	Empresa	Coke	0.13	0.49	0.35		
	Empresa	Exxon	1.01	0.79	1		
HP - ANN	Empresa	IBM	1.28	0.74	1.13	Mitra y Wang (2015)	2000-2005
	Empresa	PG	3.001	0.56	1.73		
	Empresa	DD	0.09	0.48	0.31		
	Empresa	JPM	1.94	1.04	1.39		
	Empresa	JNJ	0.82	0.61	0.91		
FLANN	Empresa	IBM		2.023		Bebarta y Rout (2016)	No Especificado.
ANN -MLP	Empresa	PETR4 STOCK		5.45	0.045	de Oliveira, et al. (2013)	01/2000 – 12/2011
Bayesian ANN	Empresa	Microsoft Corporation		1.05		Wei et al (2013)	01/2010 – 12/2012
	Empresa	Goldman Sachs Group		1.32			
	Empresa	IBM		0.63			
Fuzzy – ANN	Empresa	DELL		0.53		Hadavandi, et al. (2015)	02/2003 – 06/2005
	Empresa	British airlines		1.41			
	Empresa	Ryanair airlines		1.24			
AC/PCA -	Índice	CSI300	491.6868	0.0068		Wang, et al. (2016)	04/2011 - 12/2011
BSO/SVR	Índice	SZSE	87.6447	0.0082			

(2D)PCA+RBFNN	Índice	The Shanghai stock market index		0.000663	12.135	Guo, et al. (2015)	01/2000 - 12/2014
HS-ANN	Índice	BIST100	11236305	3381416	3352,06	Gocken, et al (2016)	06/2005 - 09/2013
NLICA-SVR	Índice	Nikkei 225		0.16	32.2	Kao, et al. (2013)	10/2007 - 11/2011
	Índice	SSEC		2.18	3.95		11/2007 - 11/2011
GARCH – ANN	Índice	NASDAQ	2478,15			Guresen, et al. (2011)	10/2008 – 06/2009
SOM – GA	Índice	TAIEX		1.44 x 10 -2	19.44	Hsu (2011)	01/1996 – 09/2009
ANFIS	Índice	TAIEX			84	Wei, et al. (2011)	2000 - 2005
NLICA-BPN	Índice	Nikkei 225		0.95	1.67	Dai, et al. (2012)	02/2004 – 03/2009
	Índice	Shanghai B-share		0.24	50.44		
ICA–BPN	Índice	TAIEX		0.49	40.54	Lu (2010)	01/2003 – 02/2006
	Índice	Nikkei 225		0.52	43.54		

Fuente: elaboración propia

De los trabajos revisados, se tienen dos grupos claramente diferenciados, los que se enfocan en la predicción del precio de acciones (empresas) y las que se enfocan en la predicción del precio de un índice (grupo de empresas). Aunque ambas utilizan muchas variables en común, los resultados alcanzados en cada una de ellas se diferencian claramente, predecir el precio de una empresa es más complicado que predecir el precio de un índice, esto debido a que los índices siguen un comportamiento menos cambiante en el tiempo, mientras que las acciones de empresas pueden tener cambios bruscos en sus precios debido a factores externos.

El presente trabajo se enfoca en la predicción de precios de empresas, por lo que se descartan los resultados de los trabajos que predijeron índices (marcados como *Índice* en la Tabla 2-6), por lo tanto, el mejor resultado alcanzado en la literatura es el modelo conformado por las técnicas HP-SVR con un valor del MAPE de 0.067% y trabajando con datos de 3 años.

También, es posible observar que el segundo mejor resultado fue obtenido por la técnica HP-ANN alcanzando un MAPE de 0.48%. Se puede ver el recurrente uso de redes neuronales en los trabajos revisados, lo cual es sustentado en la Tabla 2-6 debido a los buenos resultados que se obtiene utilizando esta técnica.

3 Capítulo 3. Revisión de las técnicas utilizadas para la predicción del precio de las acciones

En este capítulo se muestra todo lo relacionado con las técnicas utilizadas, tanto la técnica general que será KDD como también las técnicas específicas. Las técnicas específicas son seleccionadas en base a la mayor frecuencia que han sido utilizadas y la mayor precisión de los resultados que han obtenido en los 20 artículos revisados.

3.1 Técnica estándar

La predicción de los precios de las acciones en la bolsa de valores es uno de los temas de gran interés para inversores, intelectuales e investigadores debido a la volatilidad que éstos presentan. Para este fin se hace necesario definir una metodología de desarrollo para el modelo predictor, desde el análisis de los datos hasta la evaluación de los resultados.

Para este caso, se ha utilizado la metodología descubrimiento del conocimiento en Base de Datos (KDD) debido a que es considerado un modelo más completo y más exacto comparado con otros modelos como CRISP-DM y SEMMA (Umair Shafique and Haseeb Qaiser, 2014). Para algunos investigadores KDD es considerado “el proceso no trivial de identificar patrones válidos, nuevos, potencialmente útiles y en última instancia comprensible en los datos” (Fayyad, 1996 citado por Eckert & Suénaga, 2013, p. 93).

El proceso de KDD consta de cinco etapas, donde la etapa más característica y más resaltante es Data Mining (DM), donde se aplican diferentes técnicas para detectar patrones y relaciones en los datos que se presentan. “Es el paso que consiste en el uso de algoritmos concretos que generan una enumeración de patrones a partir de los datos pre-procesados” (Fayyad, 1996 citado por Eckert & Suénaga, 2013, p. 93).

Además de las cinco etapas, frecuentemente se incluye una etapa previa de análisis de las necesidades de la organización y definición del problema, en la que se establecen los objetivos de la minería de datos.

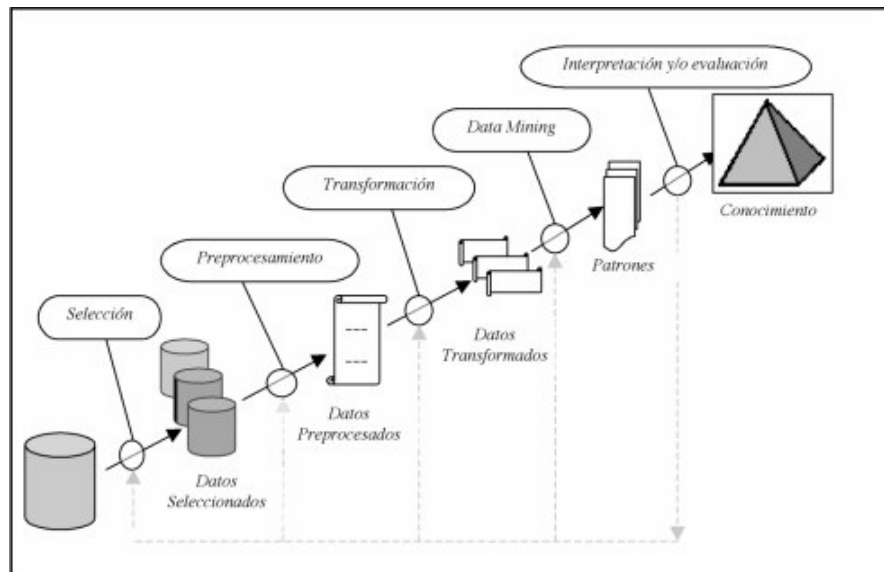


Figura 3-1. Proceso de Descubrimiento del conocimiento en Base de Datos (KDD)

Fuente: Fayyad, Shapiro, Smyth, & Uhturudsamy (1996)

A continuación se detalla las cinco etapas de este proceso:

1- Selección de datos: es la primera etapa de KDD, aquí “se determina las fuentes de datos y el tipo de información” (WebMining Consultores, 2011, párr. 2), se seleccionan las muestras de datos que serán útiles para el descubrimiento del conocimiento. Esta fase es muy importante debido a que, por ser el inicio del proceso, una adecuada selección de la muestra, que pueden ser datos, atributos o tablas pueden mejorar el desempeño del algoritmo que se utilizará en las siguientes fases.

2-Pre-Procesamiento: luego de haber realizado la selección de datos, se procede a realizar el pre- procesamiento y limpieza de datos de las muestras de datos seleccionadas. Esto consiste en eliminar datos incoherentes, registros duplicados o información innecesaria haciendo uso de diversas estrategias. Todo esto se realiza con el fin de obtener datos manejables que serán útiles para las siguientes fases (WebMining Consultores, 2011).

3-Transformación: es la tercera etapa que consiste en el enriquecimiento de los datos con otras fuentes de información, ya sean internas o externas, con el objetivo de reducir los registros, el número de variables o generar de nuevas variables a partir de las ya existentes con una estructura de datos apropiada. Aquí se realizan operaciones de agregación o normalización, consolidando los datos para la fase de Data Mining (WebMining Consultores, 2011).

4-Data Mining: es la fase más importante y más completa de todo el proceso KDD, “donde métodos inteligentes son aplicados con el objetivo de extraer patrones o modelos a partir de los datos recopilados” (WebMining Consultores, 2011, párr. 2).

5-Interpretacion y Evaluación: es la última etapa del proceso de KDD, que consiste en “identificar los patrones interesantes obtenidos, basándose en algunas medidas y se realiza una evaluación de los resultados obtenidos” (WebMining Consultores, 2011, párr. 2). Tener en cuenta que KDD es una metodología donde se puede regresar a las fases anteriores, si se desea realizar algún cambio y este mejore la precisión de los resultados.

3.2 Técnicas Específicas

3.2.1 Red Neuronal de función de base radial (RBFNN)

Es una red neuronal artificial que usa funciones de base radial como función de activación. La salida de la red es una combinación lineal de las funciones de base radial de las entradas y los parámetros de las neuronas. Esta red tiene varios usos, incluida la aproximación de funciones, predicción de series de tiempo, clasificación y sistemas de control. Es un aproximador universal, y es una alternativa popular a la red neuronal perceptrón multicapa, debido a que tiene una estructura más simple y es mucho más rápido en el proceso de entrenamiento.

Arquitectura de la red RBFNN

Generalmente, esta red tiene tres capas: una de entrada, una capa oculta con funciones de base radial no lineales y una capa de salida lineal.

La capa oculta realiza una transformación no lineal de las entradas y la capa de salida es una combinación lineal de las salidas no lineales a un nuevo espacio. Los biases de las neuronas de la capa de salida pueden ser modelados por una neurona adicional en la capa oculta, quien tiene una función de activación constante $\phi_0(r) = 1$.

La red RBFNN puede alcanzar la solución global óptima para los pesos ajustables alcanzando un mínimo MSE usando el método de optimización lineal.




Figura 3-2. Arquitectura de una Red Neuronal RBFNN

Fuente: (Sarzuri, 2014, p. 105)

Para un patrón de entrada x , la salida de la red es dada por lo siguiente:

$$y_i(x) = \sum_{k=1}^{J_2} w_{ki} \phi(\|x - c_k\|), \quad i = 1, \dots, J_3$$

Donde $y_i(x)$ es la i -ésima salida de la red RBF, w_{ki} es el peso de la conexión desde la k -ésima neurona oculta a la i -ésima de salida, c_k es el prototipo o centro de la k -ésima neurona oculta, y $\|\cdot\|$ denota la norma Euclidiana. $\phi(\cdot)$ es típicamente seleccionada como la función gaussiana. (Sarzuri, 2014, p. 105)

Aprendizaje de la red RBF

Similar a la red neuronal perceptrón multicapa, el aprendizaje de la red RBFNN es formulada como la minimización de la función MSE (error cuadrático medio):

$$E = \frac{1}{N} \sum_{i=1}^N \|y_p - W^T \phi_p\|^2 = \frac{1}{N} \|Y - W^T \phi\|_F^2$$

Donde $Y = [y_1, y_2, \dots, y_N]$, y_i es la salida objetivo del i -ésimo ejemplo en el conjunto de datos de prueba.

El aprendizaje de la red RBFNN requiere la determinación de los centros de las funciones de base radial y los pesos. La selección de los centros de las funciones de base radial es la actividad más crítica para lograr una satisfactoria implementación de una red RBFNN. Los

centros pueden colocarse en un subconjunto aleatorio o en todos los ejemplos de entrenamiento, o determinado vía clustering o mediante un proceso de aprendizaje.

Para algunas funciones de base radial, como la Gaussiana, es también necesario determinar el parámetro de suavidad σ . La red RBFNN que usa la función gaussiana es usualmente llamada red RBF Gaussiano. Los algoritmos de aprendizaje existentes son mayormente desarrollados para este tipo de red, pero pueden ser modificados cuando se requiere usar otras RBFNN.

3.2.2 SVM para Regresión (SVR)

Las Máquinas de Soporte vectorial (SVM) fueron desarrolladas inicialmente por Vapnik, et al. (1996) para construir clasificadores. Se funda en la teoría estadística del aprendizaje. Esta teoría permite escoger un clasificador que minimiza una cota superior sobre el riesgo (o error de prueba), y proporciona una buena medida para obtener clasificadores que generalizan bien sobre datos no previamente vistos.

- **SVM para problemas linealmente separables**

El algoritmo SVM trata de encontrar un hiperplano (en el ejemplo se ve un hiperplano de una dimensión: una línea) que une a las variables predictoras y constituye el límite que define si un elemento de entrada pertenece a una categoría o a la otra. (Wikipedia, s.f.a, párr. 5)




Figura 3-3. SVM para problemas separables

Fuente: (Carmona, 2014, p. 3)

- **SVM para problemas no linealmente separables**

Cuando los datos no se pueden separar linealmente se hace un cambio de espacio mediante una función que transforme los datos de manera que se puedan separar linealmente. Tal función se llama Kernel y sirve para llevar a una dimensión mayor a los datos de entrada.

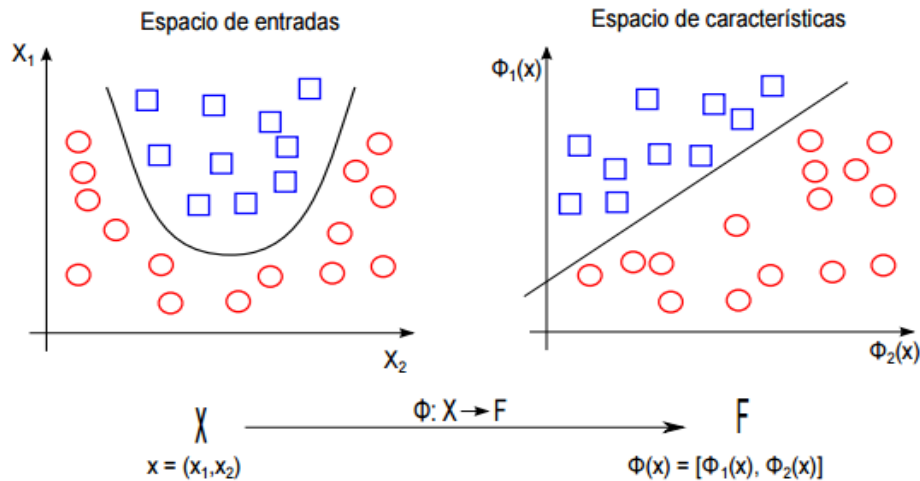


Figura 3-4. SVM para problemas no separables

Fuente: (Carmona, 2014, p. 12)

- **SVM para regresión (SVR)**

Las máquinas de vectores de soporte pueden también adaptarse para resolver problemas de regresión. En estos casos, es muy común designarlas por el acrónimo SVR. Así, dado un conjunto de ejemplos de entrenamiento $S = \{(x_1, y_1), \dots, (x_n, y_n)\}$ donde $x_i \in \mathbb{R}^d$ e $y_i \in \mathbb{R}$, en el que se asume que los valores de y_i de todos los ejemplos de S se pueden ajustar mediante una función lineal, el objetivo de la tarea de regresión es encontrar los parámetros $w = (w_1, \dots, w_d)$ que permiten definir dicha función lineal:

$$f(x) = (w_1x_1 + \dots + w_dx_d) + b = \langle w, x \rangle + b$$

Para permitir cierto ruido en los ejemplos de entrenamiento se pueden relajar la condición de error entre el valor predicho por la función y el valor real. Para ello, se utiliza la denominada función de pérdida \mathcal{E} -insensible, $L_{\mathcal{E}}$ caracterizada por ser una función lineal como una zona insensible, de anchura $2\mathcal{E}$, en la que el error es nulo y viene definida por:

$$L_{\mathcal{E}}(y, f(x)) = \begin{cases} 0 & \text{si } |y - f(x)| \leq \mathcal{E} \\ |y - f(x)| - \mathcal{E} & \text{en otro caso} \end{cases}$$

La razón principal para elegir esta función es la de permitir cierta dispersión en la función solución, de tal forma que todos los ejemplos que quedan confinados en la región tubular definida por $\pm\epsilon$ no serán considerados vectores soporte. De esta forma se reducirá significativamente el número de estos.

Dado que en la práctica es muy difícil que los ejemplos de entrenamiento se ajusten al modelo lineal con un error de predicción igual a cero, se recurre al concepto de margen blando, ya utilizado anteriormente al resolver el problema de clasificación. Para ello se definen 2 variables: ξ_i^+ y ξ_i^- , las cuales permitirán cuantificar la magnitud de dicho error. Así, la variable ξ_i^+ será mayor a cero cuando el valor real del ejemplo es mayor que su predicción en una cantidad superior a ϵ , es decir $y_i - f(x_i) > \epsilon$. En otro caso, su valor será cero. (Carmona, 2014, p. 18)




Figura 3-5. SVR con margen blanco

Fuente: (Carmona, 2014, p. 19)

“La función de optimización será la misma que la del problema de clasificación con margen blanco, con la diferencia que aquí se tiene 2 tipos de variables de holgura” (Carmona, 2014, p. 19). Por ello el problema primal en caso de regresión es:

$$\begin{aligned} \min \quad & \frac{1}{2} \langle w, x_i \rangle + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-) \\ \text{s. a.} \quad & (\langle w, x_i \rangle + b) - y_i - \epsilon - \xi_i^+ \leq 0 \\ & y_i - (\langle w, x_i \rangle + b) - \epsilon - \xi_i^- \leq 0 \\ & \xi_i^+, \xi_i^- \geq 0, \quad i = 1, \dots, n. \end{aligned} \quad (\text{Carmona, 2014, p. 19})$$

Kernel de los SVR

En el caso de que los ejemplos no puedan ajustarse por una función lineal, se recurre a una metodología similar a la utilizada en el problema de clasificación para ejemplos no separables linealmente. Es decir, los ejemplos pertenecientes al espacio original de entradas se transforman en un nuevo espacio, denominado espacio de características, en el que si es posible ajustar los ejemplos transformados mediante un regresor lineal. Este tipo de transformación dependerá del Kernel utilizado.

[...] Algunos ejemplos de funciones kernel son:

- Kernel lineal:

$$K(x, x^l) = \langle x, x^l \rangle$$

- Kernel polinomio de grado-p:

$$K_p(x, x^l) = [\gamma \langle x, x^l \rangle + r]^p$$

- Kernel gaussiano:

$$K(x, x^l) = \exp(-\gamma \|x - x^l\|^2), \gamma > 0$$

- Kernel sigmoidal:

$$K(x, x^l) = \tanh(\gamma \langle x, x^l \rangle + r), \gamma > 0$$

A los parámetros γ , r y p se les denomina parámetros del kernel. (Carmona, 2014, pp. 15- 21)

Entonces, el regresor asociado a la función lineal en el nuevo espacio es:

$$f(x) = \sum_{i=1}^n (\alpha_i^- - \alpha_i^+) K(x, x^l)$$

Se puede decir que para problemas de regresión mediante SVR hay que seleccionar, además del kernel más adecuado (en el caso de regresión no lineal), el valor del parámetro ϵ y el parámetro C . Ambos parámetros afectan la complejidad del modelo. En el caso de problemas de regresión con ruido, el valor de ϵ debería ser elegido de

forma que refleje la varianza del ruido de los datos. (Carmona, 2014, p. 22)

3.2.3 Redes Neuronales Artificiales

Redes neuronales artificiales (RNA) es una de las técnicas más utilizados en la literatura que se concentra en la predicción del precio de las acciones en la bolsa de Valores (de Oliveira, et al. 2013; Dai, et al., 2012; Lu, 2010), estos estudios utilizan distintos modelos de redes neuronales, entre las cuales una de las técnicas más frecuentes y que ha dado resultados prometedores es la Red Perceptrón multicapa (MLP) con backpropagation como algoritmo de entrenamiento, llegando a obtener una precisión aproximada del 95% en los estudios revisados.

Descripción

“El perceptrón multicapa (MLP) es una red neuronal artificial (RNA) formada por múltiples capas, esto le permite resolver problemas que no son linealmente separables, lo cual es la principal limitación del perceptrón (también llamado perceptrón simple)” (Academic, s.f., párr. 1)

Arquitectura

En general, un MLP está compuesto por una capa de entrada, una capa de salida y una o más capas ocultas; aunque se ha demostrado que para la mayoría de problemas bastará con una sola capa oculta (Funahashi, 1989; Hornik, Stinchcombe y White 1989). En la siguiente figura es posible observar un perceptrón típico formado por una capa de entrada, una capa oculta y una de salida.

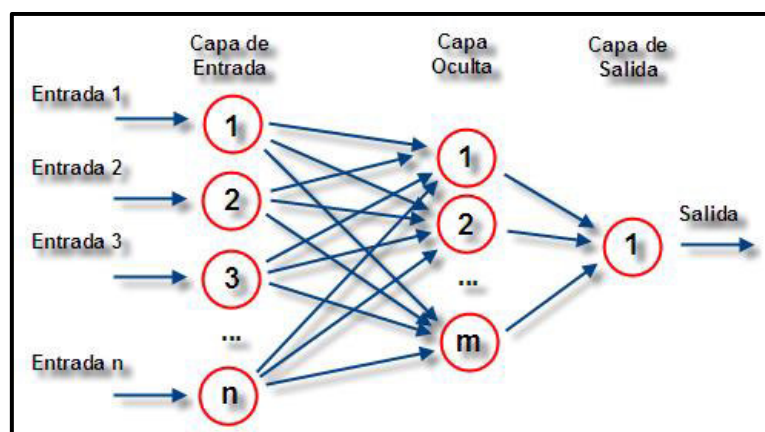


Figura 3-6. Arquitectura Básica de un perceptrón Multicapa

Fuente: (Academic, s.f., párr. 2)

En este tipo de arquitectura, las conexiones entre neuronas son siempre hacia delante (*feed forward*), es decir, las conexiones van desde las neuronas de una determinada capa hacia las neuronas de la siguiente capa; no hay conexiones laterales, esto es, conexiones entre neuronas pertenecientes a una misma capa, ni conexiones hacia atrás, esto es, conexiones que van desde una capa hacia la capa anterior. Por tanto, la información siempre se transmite desde la capa de entrada hacia la capa de salida. (AEMARK , 2016, p. 389)

Algoritmo de retro propagación (backpropagation)

Las neuronas utilizan un algoritmo de retropropagación que tiene la finalidad de propagar el error resultante a las capas ocultas y ajustar la interconexión de los pesos. La retropropagación de errores (BP) es un algoritmo de aprendizaje supervisado que se utiliza para entrenar los nodos de las capas ocultas pertenecientes a arquitecturas multicapa.

“El algoritmo BP consiste en el aprendizaje empleando un ciclo propagación-adaptación con dos fases diferenciadas: Aprendizaje hacia adelante [...] y Aprendizaje hacia atrás” (Flórez & Fernández, 2008, p. 67).

Aprendizaje hacia adelante

Cuando se presenta un patrón p de entrada $X_p: x_{p1}, \dots, x_{pi}, \dots, x_{pN}$, éste se transmite a través de los pesos w_{ji} desde la capa de entrada hacia la capa oculta. Las neuronas de esta capa intermedia transforman las señales recibidas mediante la aplicación de una función de activación, proporcionando de este modo, un valor de salida. Este se transmite a través de los pesos w_{kj} hacia la capa de salida, donde aplicando la misma operación que en el caso anterior, las neuronas de esta última capa proporcionan la salida de la red. (Marín, s.f., p. 16)

Donde la función de propagación es:

$$u_j^p = \sum_{i=1}^N w_{ji} x_i^p + \theta_j$$

El valor de salida de la neurona oculta j se obtiene aplicando una función no lineal derivable en todos sus puntos sobre su entrada neta:

$$y_j^p = f(u_j^p)$$

La función de activación en la mayoría de los casos para clasificación es una función sigmoide, mientras que para regresión es una función lineal.




Figura 3-7. Función Sigmoidal

Fuente: elaboración propia en base a (Marín, s.f., p. 21)

De igual forma, la entrada neta que recibe una neurona de salida k , está definida por su función de propagación que viene a ser:

$$u_k^p = \sum_{j=1}^M w_{kj} y_j^p + \theta_k$$

Donde el valor de la salida de la neurona sería:

$$y_k^p = f(u_k^p)$$

Aprendizaje hacia atrás

A partir de la comparación de la salida generada por la red y la salida deseada, se calcula un valor de error para cada neurona de la última capa del sistema. Estos errores se transmiten desde la capa de salida hacia las neuronas de la capa intermedia que contribuyan directamente a la salida, que reciben una parte de error aproximada a su participación en la salida original. El proceso se repite capa por capa hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al

output final. A partir del valor de error recibido, se procede al reajuste de los pesos de cada neurona para minimizar el error cometido por la red en el futuro. (Flórez & Fernández, 2008, p. 67)

El aprendizaje en las redes Backpropagation es de tipo supervisado, debido a que el usuario (o supervisor) determina la salida deseada ante la presentación de un determinado patrón de entrada.

La función de error que se pretende minimizar para cada patrón p viene dada por:

$$E_p = \frac{1}{2} \sum_{k=1}^M (t_k^p - y_k^p)^2$$

La base del algoritmo backpropagation para la modificación de los pesos es la técnica conocida como gradiente decreciente.

La forma de modificar los pesos de forma iterativa consiste en aplicar la regla de la cadena a la expresión del gradiente y añadir una tasa de aprendizaje η . Así, en una neurona de salida:

$$\Delta v_{kj}(n+1) = -\eta \frac{\partial E^p}{\partial v_{kj}} = \eta \sum_{p=1}^P \delta_k^p y_j^p$$

$$\delta_k^p = (d_k^p - y_k^p) f'(net_k^p)$$

Donde n indica la Iteración.

En una neurona oculta:

$$\Delta w_{ji}(n+1) = \eta \sum_{p=1}^P \delta_j^p x_i^p$$

$$\delta_j^p = f(net_j^p) \sum_{k=1}^M \delta_k^p v_{kj}$$

Se puede observar que el error o valor delta asociado a una neurona oculta j , viene determinado por la suma de los errores que se cometen en las k neuronas de salida que reciben como entrada la salida de esa neurona oculta j . De ahí que el algoritmo también se denomine propagación del error hacia atrás. (Marín, s.f., pp. 17-18)

4 Capítulo 4. Modelo de minería de datos para la predicción de las acciones en la bolsa de valores

En el presente capítulo se propone un modelo de minería de datos basado en descubrimiento del conocimiento en Base de Datos (KDD) para la predicción de las acciones de una empresa. Se inicia presentando el esquema general para el desarrollo del modelo, seguido de la descripción detallada de cada etapa.

4.1 Esquema general

El modelo a proponer se basa en el proceso de descubrimiento del conocimiento en base de datos (KDD) y este se sustenta fundamentalmente porque es considerada un estándar para problemas de tipo Minería de Datos y es también un método tradicional que permite convertir datos en conocimiento (Oleg, 2011). Las etapas que presenta este modelo son:

- **Selección de datos:** aparte de determinar el objetivo, se determinan las fuentes de datos, el tipo de información y se seleccionan las muestras de datos que serán útiles para el KDD.
- **Pre-Procesamiento:** se procede a hacer la preparación y limpieza de datos de las muestras seleccionadas.
- **Transformación:** consiste en la generación de variables a partir de los existentes para luego seleccionarlas, quedándose con las más importantes. Aquí se realizan operaciones de normalización.
- **Minera de datos:** es la etapa más importante del proceso de KDD, donde métodos inteligentes son aplicados con el objetivo de extraer patrones o modelos a partir de los datos recopilados.
- **Interpretación y evaluación:** es la última etapa del proceso de KDD, que consiste en identificar los patrones obtenidos, basándose en algunas medidas para luego realizar una evaluación de resultados.

A continuación, se presenta el modelo propuesto basado en KDD para resolver el problema de predicción de los precios de las acciones.

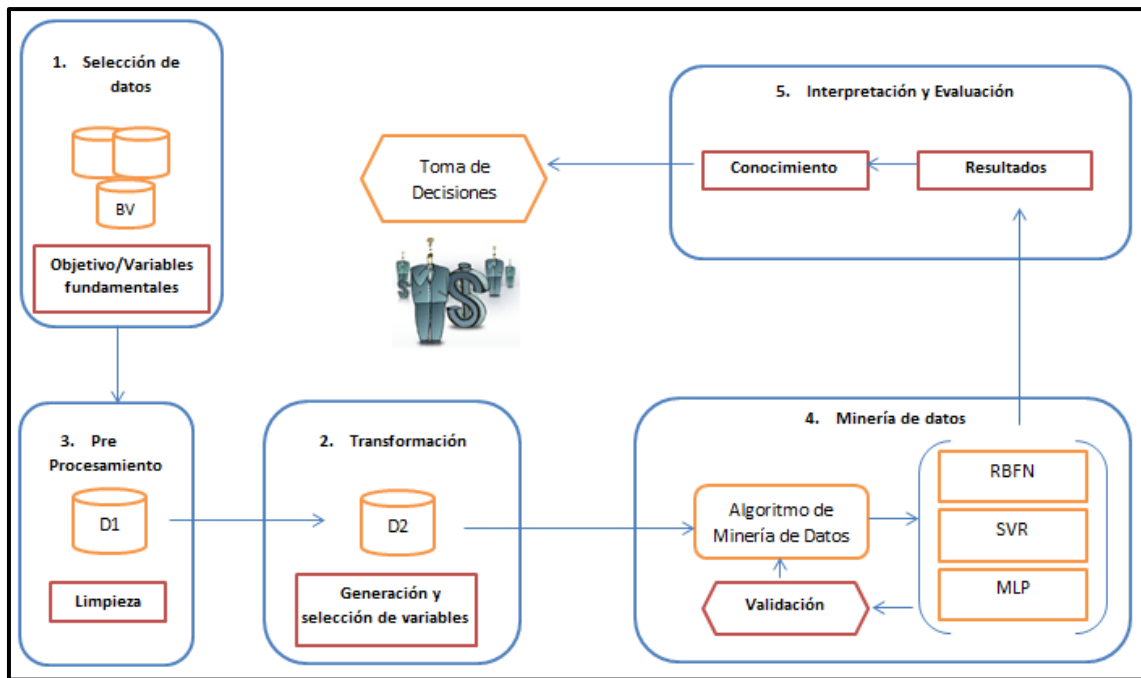


Figura 4-1. Modelo propuesto

Fuente: elaboración propia

La primera etapa es la identificación de la fuente de datos, se eligió las páginas www.finance.yahoo.com e www.investing.com debido a que permitía obtener los valores históricos de las variables fundamentales de cualquier acción como también de los metales e índices. La segunda etapa es el pre procesamiento, que contiene la generación de nuevas variables y limpieza de datos, en primera instancia se calcularon los indicadores técnicos a partir de las cinco variables fundamentales y luego se estandarizan los datos dentro de un mismo rango, eliminando los datos inconsistentes. La tercera etapa consiste en la selección de variables, en la cual se utiliza la técnica de “Análisis de correlación”, permitiendo seleccionar las variables más influyentes en la predicción del precio de una acción, estas variables sirvieron de entrada a la cuarta etapa, donde se hace uso de tres técnicas de minería de datos: Red neuronal de función radial (RBFN), Regresión de Vectores de Soporte (SVR) y Redes Neuronales Artificiales (ANN); para que luego los resultados de estas técnicas junto con las variables iniciales ingresen al modelo híbrido, donde la técnica elegida para este modelo híbrido fue la que mejor resultados dio en las técnicas específicas. Para finalizar, se realizó la interpretación y evaluación de resultados del modelo que servirán como puntos clave para la toma de decisiones en la inversión, estas se detallan en el Capítulo 6.

4.2 Etapa 1: Selección de datos

El problema de predecir el precio de una acción ha tomado mayor importancia en el mercado financiero, debido a que es un problema de mucha incertidumbre para los inversionistas e investigadores y conocer estos resultados generaría ganancias significativas.

Esta primera etapa de selección de datos consiste en seleccionar la fuente de datos como también las muestras de datos que serán útiles. Para la presente tesis, los datos con los que se trabajará serán datos de la Bolsa de Valores de Nueva York, haciendo énfasis principalmente en las acciones de empresas mineras que cotizan en dicha bolsa.

Es consabido que, Estados Unidos cuenta con el mayor mercado de valores del mundo, tanto en tamaño como en actividad. De las ocho bolsas que funcionan en el país, se seleccionó la Bolsa de Valores de Nueva York (NYSE), debido a que es la más importante y conocida internacionalmente, además que el volumen de acciones cotizadas es mucho mayor en comparación con otras bolsas.

Los datos históricos de las acciones que serán extraídas son de cinco compañías mineras: Buena ventura, Barrick Gold Corporation, BHP Billiton Limited, Fortuna Silver Mines y Southern Copper; debido a que estas acciones son más volátiles y generarían mayor ganancia en un corto plazo. Buena ventura, Fortuna Silver Mines y Southern Copper son compañías mineras con sedes en Perú dedicadas a la exploración, extracción, fundición y comercialización de oro y plata, así como otros metales y minerales.

Los datos históricos para las variables fundamentales de las acciones de las empresas mencionadas fueron extraídos de la página www.finance.yahoo.com, el cual es una web que permite obtener los datos fundamentales para la predicción (precio de apertura, precio máximo, precio mínimo, precio de cierre y volumen) y para las variables nuevas (precio de los metales, índices y dólar) se utilizó la página www.investing.com, que permite obtener los datos históricos del oro, plata y otros metales. Se extrajeron cinco variables fundamentales, durante el período de 3 años con observaciones diarias dando un total de 1.068 registros. La periodicidad de la información es muy importante para el proceso de predicción, ya que a menor periodicidad de las muestras, más difícil la predicción.

Es importante tener en cuenta que, en el mercado bursátil, los precios pueden ser muestreados con la siguiente periodicidad: en tiempo real, minuto, hora, día, semana, mes, etc. En esta investigación, las predicciones son diarias debido a que las acciones de la bolsa de

Nueva York son muy volátiles y las cotizaciones que se realizan son en periodos cortos de tiempo.

4.3 Etapa 2: Pre-procesamiento

Se llevó a cabo un proceso de limpieza de los datos, que consiste en la eliminación de datos inconsistentes. Debido a que las observaciones de las variables fueron diarias, estas contienen datos faltantes en los días que la bolsa no opera (feriados o días en los que no hay comercio), como solución se procedió a aplicar el siguiente método:

- **Eliminación de registros:** esta solución se basa en eliminación de todos aquellos datos diarios que tengan uno o más valores faltantes.

Esto se observa principalmente debido a que del conjunto de variables, una de las variables es el precio del día anterior, pero este dato no existe en algunos registros (registros donde el día siguiente es un día en el que la bolsa de valores no opera), por lo que se procedió a eliminarlos.

4.4 Etapa 3: Transformación

Variables fundamentales:

Las variables fundamentales mostradas en la Tabla 4-1 son aquellas que se consideran para la generación posterior de los indicadores técnicos y son extraídas directamente de la página Yahoo Finance. Se consideró también la variable fecha únicamente para realizar los cálculos de los indicadores técnicos, los cuales consideraban promedios móviles en intervalos de tiempo dados.

Tabla 4-1. *Variables Fundamentales*

Variable	Descripción	Tipo variable	Referencia
Precio de apertura	Es el primer precio de una acción determinada en un diario de negociación.	Continua	de Oliveira, et al. (2013), Hadavandi, et al. (2015), Lu (2010), Laboissiere, et al. (2015), Wang, et al. (2016), Mitra y Wang (2015), Ouahilal et al. (2016), Joao et al. (2014), Ticknor et al. (2013).
Precio de cierre	Es el precio de la última transacción dada el final de un diario de negociación.	Continua	de Oliveira, et al. (2013), Hadavandi et al (2015), Gocken, et al (2016), Kao et al, Wang, et al. (2016), Mitra y Wang (2015), Ouahilal, et al. (2016), Joao, et al. (2014), Ticknor (2013).
Precio mínimo	Es el precio más alto que se pagó por una acción en un diario de negociación.	Continua	de Oliveira, et al. (2013), Hadavandi, et al. (2015), Gocken, et al (2016), Wang, et al. (2016), Mitra y Wang (2015),

Precio máximo	Es el precio más bajo que se pagó por una acción en un diario de negociación.	Continua	Ouahilal et al. (2016), Joao, et al. (2014), Ticknor (2013). de Oliveira, et al. (2013), Hadavandi, et al (2015), Gocken, et al (2016), Wang, et al (2016), Mitra y Wang (2015), Ouahilal et al. (2016), Joao, et al. (2014), Ticknor (2013).
Volumen	Es la cantidad de acciones que son compradas o vendidas en un día.	Discreta	de Oliveira, et al. (2013), Lu (2010), Wang, et al. (2016), Ouahila, et al. (2016), Ticknor (2013).

Fuente: elaboración propia

Variables técnicas

Teniendo las variables fundamentales como base, se calculan los siguientes indicadores técnicos utilizando las formulas del Anexo 1. Las variables calculadas son:

Tabla 4-2. *Variables técnicas calculadas a partir de las variables fundamentales*

Variable	Descripción	Tipo variable	Referencia
Precio de cierre del día previo	Es el precio de la última transacción realizada un día previo al actual.	Continua	Dai, et al. (2012), Lu (2010), Chang (2011), Gocken, et al (2016), Laboissiere, et al. (2015).
Precio máximo del día previo	Es el precio máximo que alcanzó la acción un día previo al actual.	Continua	Gocken, et al. (2016), Laboissiere, et al. (2015), Dai et al. (2012), Lu (2010).
Precio mínimo del día previo	Es el precio mínimo que alcanzó la acción un día previo al actual.	Continua	Gocken, et al (2016), Laboissiere et al (2015), Dai, et al. (2012), Lu (2010)
Precio de apertura del día anterior	Es el precio de apertura de la acción un día previo al actual.	Continua	Laboissiere, et al (2015).
Indicador de fuerza relativa(RSI)	Mide la fuerza con la que suben o bajan los precios.	Continua	de Oliveira, et al. (2013), Wei et al (2011), Wei et al (2013), Lu (2010), Gocken, et al. (2016), Wang, et al. (2016), Bebart, et al. (2015), Hsu (2011), Ticknor (2013).
Momentum	Indicador que mide la aceleración y desaceleración en los cambios de los precios entre dos instantes en el tiempo.	Continua	de Oliveira, et al. (2013), Gocken, et al (2016), Hsu (2011).
Índices Estocásticos	Indicador que compara el precio de cierre de hoy con precios de días anteriores	Continua	de Oliveira, et al. (2013), Wei, et al. (2011), Wei et al (2013), Gocken, et al (2016), Hsu (2011), Ticknor (2013).
Promedios móviles	Indicadores que allanan o suavizan, en mayor o menor medida, la evolución de las cotizaciones.	Continua	de Oliveira, et al. (2013), Wei et al (2011), Wei et al (2013), Gocken, et al (2016), Hsu (2011), Ticknor (2013).
Willian R%	Indicador que mide que tan cerca del máximo o del mínimo han cerrado los precios.	Continua	de Oliveira, et al. (2013), Wei et al (2011), Gocken, et al

			(2016), Hsu (2011), Ticknor (2013).
Balance de volúmenes (OBV)	Balance de volúmenes.	Continua	de Oliveira, et al. (2013).
Banda media de Bollinger	Promedio móvil entre la banda alta y baja de Bollinger.	Continua	de Oliveira, et al. (2013), Gocken, et al. (2016).
Promedio móvil ponderado del dólar	Es el promedio ponderado del precio del dólar en un intervalo de 21 días.	Continua	Laboissiere et al. (2015).

Fuente: elaboración propia

Tabla 4-2 (*Continuación*).

Variable	Descripción	Tipo variable	Referencia
Banda alta de Bollinger	Es la máxima desviación negativa que tiene la banda media.	Continua	de Oliveira, et al. (2013), Gocken, et al. (2016).
Precio medio	Precio medio en el día de la acción.	Continua	Gocken, et al. (2016)
Monto	Es el valor nominal del monto de las acciones compradas o vendidas en un día.	Discreta	Wang, et al. (2016).
BIAS	Relación de sesgo.	Continua	Wang, et al. (2016), Hsu (2011).
Indicador de cambio del volumen del precio(PVC)	Mide la variación del volumen multiplicado por el precio.	Continua	Bebarta, et al. (2015).
Indicador de volumen móvil promedio(MAVI)	Mide la variación del volumen promedio.	Continua	Bebarta, et al. (2015).
Relación acumulativa (AR)	Relación acumulativa.	Continua	Hsu (2011).
Movimiento promedio de Convergencia/Divergencia (MACD)	Trabaja como una medida filtrada del derivado del precio de las acciones con respecto al tiempo.	Continua	de Oliveira, et al. (2013), Hsu (2011).
Indicador de momento de compra / venta (AR)	Es el índice que indica el momento de la compra y venta.	Continua	Hsu (2011).
Indicador de la voluntad de compra / venta (BR)	Es un índice que indica el momento de la propensión a la compra y venta.	Continua	Hsu (2011).
Tasa de cambio (ROC)	Es un indicador técnico que mide la tasa de cambio del precio en relación a periodos anteriores.	Continua	Wang, et al. (2016), Hsu (2011).
Indicador direccional (DI)	Este indicador representa la fuerza que ha tenido el movimiento de hoy en comparación con el rango verdadero.	Continua	Hsu (2011).
Linea psicológica (PSY)	Es un indicador de sentimiento, utilizado para predecir las reversiones a corto plazo del mercado.	Continua	Wang, et al. (2016), Hsu (2011), Wei, et al (2011).

Diferencia (DIF)	Diferencia entre el precio de cierre del día actual y el día previo.	Continua	Wang, et al. (2016).
------------------	--	----------	----------------------

Fuente: elaboración propia

Llama la atención que, una cantidad considerable de las investigaciones revisadas utilizan el análisis técnico sobre las variables fundamentales para predecir el precio de una acción y dejan de lado otras variables como las variables propias del sector al que pertenece la empresa en revisión, por lo que con el fin de introducir nuevas variables se llevó a cabo una encuesta dirigida a seis expertos en los mercados financieros, siguiendo el proceso descrito a continuación:

- **Se estructuró una encuesta (Anexo 2), en la cual se evaluaba:**
 - Años de experiencia en mercados financieros.
 - Tipo de mercado en el cual operaban (bolsa de valores o fórex).
 - Variables que a su criterio y experiencia consideran al invertir en acciones mineras.
- **Se seleccionó un grupo de seis expertos tomando como criterio los años de experiencia en la bolsa valores (Experiencia > 5 años).**
 - Se realizó la evaluación al grupo de expertos seleccionados.
 - Se obtuvieron métricas de los resultados obtenidos que sirvieron para la toma de decisión de las variables.

Las respuestas de esta evaluación se clasifican en dos grupos: selección de expertos y selección de variables.

Sobre los expertos

Se encuestaron a seis expertos, con un promedio de experiencia laboral de 12 años. El 83.3% de los expertos han operado en el mercado de acciones, de los cuales cinco de ellos han invertido directamente en el sector minero, esto es un factor importante porque los factores mencionados por dichas personas tiene mayor peso que aquellos que nunca han invertido en el sector.




Figura 4-2. Mercados de la bolsa

Fuente: elaboración propia



Figura 4-3. Acciones mineras - expertos

Fuente: elaboración propia

G

Selección de variables de los expertos

Tomando como base la información de los expertos, se encuentra que de las respuestas obtenidas, se obtuvieron siete variables que serían consideradas influyentes en la predicción del precio de una acción minera en la bolsa de valores, las variables a las que se hace referencia son:

- Precio de cierre de los índices: IGBVL, Down Jones y NASDAQ.

Los índices representativos de los mercados de valores de EE.UU y Perú cuando la acción es comercializada en dicho mercado, son considerados como una de las variables propuestas por los expertos. Si bien fue mencionada solo una vez, la razón por la que es seleccionada es por la importancia que se le dio en la encuesta ya que se mencionó que el precio del índice más representativo de una bolsa tiene una relación directa con las acciones que estas comercializan. Así que si, el índice de una acción es ascendente es probable que el precio de la acción también lo sea.

Por ello para esta investigación, los mercados de valores que están relacionados con las acciones mineras se encuentran en Lima y la de EE.UU, donde los índices representativos para cada uno son:

- Bolsa de Valores de Lima: IGBVL
- Bolsa de Valores de EE.UU: DJI, NASDAQ.
- Precios de metales comercializados en las empresas seleccionadas.

Cinco de seis expertos mencionan que una factor que todo inversionista debería considerar son los precios de los metales (Figura 4-4), porque si bien existen muchas empresas mineras, cada una de estas se especializan en tres o cuatro tipo de metales diferentes, por ejemplo, si el oro está subiendo entonces es probable que las empresas que comercializan oro también tengan un crecimiento ascendente.




Figura 4-4. Importancia de los metales

Fuente: elaboración propia

Por ello, como son cinco empresas seleccionadas del sector minero, se obtuvo que los metales más importantes por cada empresa, los cuales serán considerados posibles variables de entrada en los modelos son:

- Buena ventura: oro, plata, cobre, zinc.
- Barrick Gold Corporation: oro, plata, cobre.
- BHP Billiton Limited: oro, plata, cobre, zinc.
- Fortuna Silver Mine: oro, plata, zinc.
- Southern Copper: oro, plata, cobre, zinc.

- Precio del dólar

El precio del dólar es también un factor mencionado, puesto que las materias primas cotizan en dólares en los mercados internacionales, además el dólar tiene una relación inversa con los metales, entonces si el dólar baja es probable que el precio de los metales suban y con esto el precio de la acción minera.




Figura 4-5. Importancia del oro

Fuente: elaboración propia

El cuadro siguiente muestra el detalle de las variables más mencionadas, tomando como base los índices más importantes.

Tabla 4-3. Variables indicadas por los expertos

Variable	Descripción	Tipo de Variable
Precio de cierre IGBVL	Es el precio de la última transacción del índice bursátil más importante del mercado de acciones de Lima.	Continua
Precio de cierre DJI	Es el precio de la última transacción del índice bursátil con acciones más significativas de todas las industrias en EE.UU.	Continua
Precio de cierre NASDAQ	Es el precio de la última transacción del índice bursátil de NASDAQ.	Continua
Precio del dólar	Precio diario del dólar.	Continua
Precio del oro	Precio diario del Oro.	Continua
Precio de la plata	Precio diario de la plata.	Continua
Precio del Cobre	Precio diario del cobre.	Continua
Precio del Zinc	Precio diario del zinc.	Continua

Fuente: elaboración propia

En base a este análisis previo, concluimos que las variables utilizadas en este estudio, se basan en las variables fundamentales (Tabla 4-1), luego las variables técnicas (Tabla 4-2), y por último se adiciona las variables mencionadas por expertos (Tabla 4-3), los cuales a su punto de vista se debe considerar cuando se evalúa invertir en dichas acciones mineras.

Adicional a ello, Atsalakis y Valavanis (2009) citados por de Oliveira, et al. (2013) “presentaron un estudio de varios enfoques para predecir el comportamiento del mercado de

valores, 75 estudios utilizaron análisis técnicos y sólo 18 utilizaron análisis fundamentales, una proporción mucho menor” (p. 7597).

Resumiendo, el comportamiento del precio es afectado de la siguiente manera:

$$=F_{RBFN/SVR/MLP}(\text{Variables Fundamentales} + \text{Variables Técnicas} + \text{Variables de expertos}) \quad (1)$$

Selección de variables

Luego de la identificación y pre procesamiento de todas las variables que influyen en el precio de acciones mineras, se continúa con la selección de variables, este proceso es muy importante para reducir el número de atributos y usar solo los atributos más relevantes en la predicción (Laboissiere, et al, 2015).

Del Capítulo 2, se muestran las técnicas de selección de variables en la literatura, se identifica la técnica más utilizada en el problema de predicción del precio en la bolsa Valores: el análisis de correlación, el cual ha sido utilizado en cuatro trabajos de la literatura (Wei et al, 2011; Laboissiere et al, 2015; Wang et al, 2016; Oliveira, et al. 2013), y es elegida como método para la selección de variables esenciales en el presente trabajo.

Esta técnica permite realizar una selección de variables basada en un análisis de correlación entre un posible atributo de entrada y la salida deseada, donde al final, se consideran las variables con la correlación más alta. Para este estudio las variables de entrada y de salida son, respectivamente: las variables mencionadas en la etapa de pre procesamiento [Eq. (1)] y el precio de cierre del día siguiente para cada acción minera.

El coeficiente usado para medir la correlación es el coeficiente de Pearson, el cual representa una medida de la relación lineal entre dos variables aleatorias cuantitativas y se define como la relación entre la covarianza de dos variables ‘X’, ‘Y’ y la multiplicación de sus desviaciones estándar correspondientes (Wikipedia, s.f.b).

$$-1 \leq r = \frac{Cov(X,Y)}{S_X S_Y} = \frac{\sum_{t=1}^n (X_t - \bar{X}) * (Y_t - \bar{Y})}{\sqrt{\sum_{t=1}^n (X_t - \bar{X})^2} * \sqrt{\sum_{t=1}^n (Y_t - \bar{Y})^2}} \leq +1$$

Donde:

- X: Variable de entrada en el modelo.
- Y: Variable de salida, precio de cierre a predecir.
- $Cov(x,y)$: Es la covarianza de (x, y)

Como se puede observar, esta relación varía entre -1 y 1, donde un valor de -1 representa una correlación negativa perfecta, esto indica una dependencia total entre las dos variables llamada relación inversa: cuando una de ellas aumenta, la otra disminuye en proporción constante, el valor de 1 representa una relación directa, cuando una de ellas aumenta, la otra también lo hace en proporción constante.

Por otra parte, Wang et al. (2016) consideró que cuando el coeficiente de correlación de las variables es inferior a 0.3428 y mayor a -0.3428; estas se descartan del conjunto de muestras, dado que tenían baja representatividad en su modelo. Considerando este valor propuesto por Wang et al. (2016) se propuso un valor mayor de correlación (valor 0.8) con el fin de seleccionar solo las variables mejor relacionadas.

En general, luego de realizar las pruebas para los dos valores de correlación, se optó por 0.8 por los mejores resultados obteniendo, entonces si $r \geq 0.8$ indica una relación positiva, $r < -0.8$ indica una relación negativa, mientras que $-0.8 \leq r \leq 0.8$ indica que no hay relación en caso el valor sea 0, caso contrario las variables son independientes y no están relacionadas.

Tabla 4-4. *Valores de correlación*

Valor de r	Fuerza de correlación
$r \geq 0.8$	Relación positiva
$r \leq -0.8$	Relación negativa
$R=0$	No hay relación

Fuente: elaboración propia

Análisis de correlación

Para el análisis de correlación de cada empresa minera, se consideró las siguientes variables:

- Variables fundamentales (5 variables)
- Variables técnicas (27 variables)
- Variables de los metales (Depende de qué metales comercializa la empresa).

- Variable del dólar
- Variable de los índices (Depende de los mercados de valores donde se comercializa tanto en EE.UU o Perú)

Buenaventura (BVN)

Para el análisis de correlación de Buenaventura, se consideró los metales: cobre, oro, plata, zinc; debido a que son estos los metales que Buenaventura extrae y comercializa, para la variable de los índices de las bolsas se consideró: el índice de la bolsa de valores de Lima, debido a que la acción es comercializada en este mercado, además de los índices: DJ y Nasdaq por ser índices representativos de los mercados de EE.UU donde Buenaventura comercializa.

En base a estas variables junto con las variables técnicas y fundamentales, se obtuvieron los siguientes resultados al aplicar el coeficiente de correlación, donde las variables sombreadas son las seleccionadas a eliminar:

Resultados del análisis de correlación - Variables técnicas			
Factor	Valor R	Factor	Valor R
Apertura	0.98835	Banda media Bollinger	0.95585
Alto	0.99129	Banda superior Bollinger	0.95343
Bajo	0.99104	Precio Medio	0.99260
Cierre	0.99315	Monto	0.34285
Volumen	-0.19432	Bias_20	0.18894
Precio anterior	0.98734	PVC	-0.02685
Precio Máximo Anterior	0.98548	MAVI	-0.08128
Precio Mínimo Anterior	0.98518	MACD	-0.15696
Precio Apertura Anterior	0.98277	AR_26	0.21318
RSI	-0.25168	BR_26	0.18724
Momentum	0.17653	ROC10	0.13909
Índice K	0.18487	DI14 Positivo	0.51152
Índice D	0.23735	DI14 Negativo	-0.09147
PM_10	0.97637	Línea psicológica	0.08525
William	-0.12950	Diferencia	0.05026
OBV	0.71898	CCI24	0.20682

Fuente: elaboración propia

Para las variables nuevas relacionadas con los metales de las empresas, los índices y el dólar se obtuvieron los siguientes resultados:

Factor	Valor R
Precio cobre	0.38880
Precio oro	0.73576
Precio plata	0.83310
Precio zinc	0.63800
Dólar	-0.15894
DJ	0.52504
IGBVL	0.57429
NASDAQ	0.33227

Fuente: elaboración propia

Donde, luego de aplicar el coeficiente de correlación y elegir las variables que cumplían los criterios mencionados (valor absoluto mayor a 0.8), se seleccionó las siguientes variables:

Factor	Valor R	Factor	Valor R
Apertura	0.98835	Precio Plata	0.83310
Alto	0.99129		
Bajo	0.99104		
Cierre	0.99315		
Precio anterior	0.98734		
Precio Máximo Anterior	0.98548		
Precio Mínimo Anterior	0.98518		
Precio Apertura Anterior	0.98277		
PM_10	0.97637		
Middle Band Bollinger	0.95585		
Upper Band Bollinger	0.95343		
Precio Medio	0.99260		

Fuente: elaboración propia

Barrick Gold Corporation (ABX)

Para el análisis de correlación de Buenaventura, se consideró los metales: cobre, oro y plata; debido a que son estos los metales que Barrick extrae y comercializa, para las variables de los índices de las bolsas se consideró solo los índices representativos de EE.UU: DJ y Nasdaq por ser los mercados donde Barrick comercializa.

Con base en estas variables junto con las variables técnicas y fundamentales, se obtuvieron los siguientes resultados al aplicar el coeficiente de correlación, donde las variables sombreadas son las seleccionadas a eliminar:

Resultados del análisis de correlación - Variables técnicas			
Factor	Valor R	Factor	Valor R
Apertura	0.99190	Banda media Bollinger	0.96507

Alto	0.99378	Banda superior Bollinger	0.96450
Bajo	0.99387	Precio Medio	0.99474
Cierre	0.99510	Monto	0.44490
Volumen	-0.20848	Bias_20	0.17149
Precio anterior	0.99060	PVC	-0.13168
Precio Máximo Anterior	0.98946	MAVI	-0.10142
Precio Mínimo Anterior	0.98944	MACD	-0.21191
Precio Apertura Anterior	0.98741	AR_26	-0.06442
RSI	-0.20819	BR_26	0.12066
Momentum	0.15856	ROC10	0.13312
Índice K	0.17721	DI14 Positivo	0.43121
Índice D	0.22358	DI14 Negativo	0.05231
PM_10	0.98141	Línea psicológica	0.20923
William	-0.14662	Diferencia	0.04589
OBV	0.84725	CCI24	0.17817

Fuente: elaboración propia

Para las variables nuevas relacionadas con los metales de las empresas, los índices y el dólar se obtuvieron los siguientes resultados:

Factor	Valor R
Precio cobre	0.12336
Precio oro	0.85543
Precio plata	0.82635
Dólar	-0.14317
DJ	0.45461
NASDAQ	0.28234

Fuente: elaboración propia

Donde, luego de aplicar el coeficiente de correlación y elegir las variables que cumplían los criterios mencionados (valor absoluto mayor a 0. 8), se seleccionó las siguientes variables:

Factor	Valor R	Factor	Valor R
Apertura	0.99190	Precio Oro	0.85543
Alto	0.99378	Precio Plata	0.82635
Bajo	0.99387		
Cierre	0.99510		
Precio anterior	0.99060		
Precio Máximo Anterior	0.98946		
Precio Mínimo Anterior	0.98944		
Precio Apertura Anterior	0.98741		
PM_10	0.98141		
OBV	0.84725		
Middle Band Bollinger	0.96507		

Upper Band Bollinger	0.96450
Precio Medio	0.99474

Fuente: elaboración propia

BHP Billiton Limited (BHP)

Para el análisis de correlación de Buenaventura, se consideró los metales: cobre, oro y plata; debido a que son estos los metales que Billiton extrae y comercializa, para las variables de los índices de las bolsas se consideró solo los índices representativos de EE.UU: DJ y Nasdaq por ser los mercados donde Billiton comercializa.

En base a estas variables junto con las variables técnicas y fundamentales, se obtuvieron los siguientes resultados al aplicar el coeficiente de correlación, donde las variables sombreadas son las seleccionadas a eliminar:

Resultados del análisis de correlación - Variables técnicas			
Factor	Valor R	Factor	Valor R
Apertura	0.99689	Banda media Bollinger	0.98351
Alto	0.99738	Banda superior Bollinger	0.98050
Bajo	0.99737	Precio Medio	0.99759
Cierre	0.99770	Monto	0.13266
Volumen	-0.50306	Bias_20	-0.00493
Precio anterior	0.99527	PVC	0.00556
Precio Máximo Anterior	0.99490	MAVI	0.02039
Precio Mínimo Anterior	0.99480	MACD	-0.58514
Precio Apertura Anterior	0.99429	AR_26	-0.08086
RSI	0.04259	BR_26	0.02865
Momentum	-0.06150	ROC10	-0.01624
Índice K	-0.03925	DI14 Positivo	-0.18716
Índice D	-0.03088	DI14 Negativo	0.05410
PM_10	0.99088	Línea psicológica	-0.11429
William	0.03953	Diferencia	-0.02425
OBV	0.77561	CCI24	-0.05531

Fuente: elaboración propia

Para las variables nuevas relacionadas con los metales de las empresas, los índices y el dólar se obtuvieron los siguientes resultados:

Factor	Valor R
Precio cobre	0.93388
Precio oro	0.18018

Precio plata	0.38557
Precio zinc	0.30399
Dólar	-0.74295
DJ	-0.11776
NASDAQ	-0.38348

Fuente: elaboración propia

Donde, luego de aplicar el coeficiente de correlación y elegir las variables que cumplieran los criterios mencionados (valor absoluto mayor a 0.8), se seleccionó las siguientes variables:

Factor	Valor R	Factor	Valor R
Apertura	0.99689	Precio Cobre	0.93387
Alto	0.99738		
Bajo	0.99737		
Cierre	0.99770		
Precio anterior	0.99527		
Precio Máximo Anterior	0.99490		
Precio Mínimo Anterior	0.99480		
Precio Apertura Anterior	0.99429		
PM_10	0.99088		
Middle Band Bollinger	0.98351		
Upper Band Bollinger	0.98050		
Precio Medio	0.99759		

Fuente: elaboración propia

Fortuna Silver Mines (FSM)

Para el análisis de correlación de Buenaventura, se consideró los metales: oro, plata, zinc debido a que son estos los metales que Fortuna extrae y comercializa, para las variables de los índices de las bolsas se consideró solo los índices representativos de EE.UU: DJ y Nasdaq por ser los mercados donde Fortuna comercializa. Si bien esta minera tiene yacimientos en Perú, sus acciones no comercializan en la BVL, por ello el índice IGBVL no es considerado.

En base a estas variables junto con las variables técnicas y fundamentales, se obtuvieron los siguientes resultados al aplicar el coeficiente de correlación, donde las variables sombreadas son las seleccionadas a eliminar:

Resultados del análisis de correlación - Variables técnicas			
Factor	Valor R	Factor	Valor R
Apertura	0.98784	Banda media Bollinger	0.95953
Alto	0.99064	Banda superior Bollinger	0.95993
Bajo	0.99049	Precio Medio	0.99197

Cierre	0.99232	Monto	0.66457
Volumen	0.52107	Bias_20	0.18068
Precio anterior	0.98623	PVC	-0.01615
Precio Máximo Anterior	0.98508	MAVI	0.00423
Precio Mínimo Anterior	0.98492	MACD	-0.07610
Precio Apertura Anterior	0.98250	AR_26	0.02779
RSI	-0.19187	BR_26	0.13042
Momentum	0.15956	ROC10	0.15173
Índice K	0.16393	DI14 Positivo	0.77083
Índice D	0.19838	DI14 Negativo	-0.53672
PM_10	0.97593	Línea psicológica	0.09267
William	-0.13549	Diferencia	0.04571
OBV	0.10037	CCI24	0.18593

Fuente: elaboración propia

Para las variables nuevas relacionadas con los metales de las empresas, los índices y el dólar se obtuvieron los siguientes resultados:

Factor	Valor R
Precio oro	0.81151
Precio plata	0.82073
Precio zinc	0.46024
Dólar	-0.01038
DJ	0.41060
IGBVL	0.42249
NASDAQ	0.29908

Fuente: elaboración propia

Donde, luego de aplicar el coeficiente de correlación y elegir las variables que cumplían los criterios mencionados (valor absoluto mayor a 0. 8), se seleccionó las siguientes variables:

Factor	Valor R	Factor	Valor R
Apertura	0.98784	Precio oro	0.81151
Alto	0.99064	Precio plata	0.82073
Bajo	0.99049		
Cierre	0.99232		
Precio anterior	0.98623		
Precio Máximo Anterior	0.98508		
Precio Mínimo Anterior	0.98492		
Precio Apertura Anterior	0.98250		
PM_10	0.97593		
Middle Band Bollinger	0.95953		

Upper Band Bollinger	0.95993
Precio Medio	0.99197

Fuente: elaboración propia

Southern Copper (SCC)

Para el análisis de correlación de Buenaventura, se consideró los metales: cobre, oro, plata y zinc; puesto que son estos los metales que Southern Copper extrae y comercializa, para la variable de los índices de las bolsas se consideró: el índice de la bolsa de valores de Lima, debido a que la acción es comercializada en este mercado, además de los índices: DJ y Nasdaq por ser índices representativos de los mercados de EE.UU donde Buenaventura comercializa.

En base a estas variables junto con las variables técnicas y fundamentales, se obtuvieron los siguientes resultados al aplicar el coeficiente de correlación, donde las variables sombreadas son las seleccionadas a eliminar:

Resultados del análisis de correlación - Variables técnicas			
Factor	Valor R	Factor	Valor R
Apertura	0.98784	Banda media Bollinger	0.95953
Alto	0.99064	Banda superior Bollinger	0.95993
Bajo	0.99049	Precio Medio	0.99197
Cierre	0.99232	Monto	0.66457
Volumen	0.52107	Bias_20	0.18068
Precio anterior	0.98623	PVC	-0.01615
Precio Máximo Anterior	0.98508	MAVI	0.00423
Precio Mínimo Anterior	0.98492	MACD	-0.07610
Precio Apertura Anterior	0.98250	AR_26	0.02779
RSI	-0.19187	BR_26	0.13042
Momentum	0.15956	ROC10	0.15173
Índice K	0.16393	DI14 Positivo	0.77083
Índice D	0.19838	DI14 Negativo	-0.53672
PM_10	0.97593	Línea psicológica	0.09267
William	-0.13549	Diferencia	0.04571
OBV	0.10037	CCI24	0.18593

Fuente: elaboración propia

Para las variables nuevas relacionadas con los metales de las empresas, los índices y el dólar se obtuvieron los siguientes resultados:

Factor	Valor R
--------	---------

Precio oro	0.81151
Precio plata	0.82073
Precio zinc	0.46024
Dólar	-0.01038
DJ	0.41060
IGBVL	0.42249
NASDAQ	0.29908

Fuente: elaboración propia

Donde, luego de aplicar el coeficiente de correlación y elegir las variables que cumplían los criterios mencionados (valor absoluto mayor a 0.8), se seleccionó las siguientes variables:

Factor	Valor R	Factor	Valor R
Apertura	0.98784	Precio oro	0.81151
Alto	0.99064	Precio plata	0.82073
Bajo	0.99049		
Cierre	0.99232		
Precio anterior	0.98623		
Precio Máximo Anterior	0.98508		
Precio Mínimo Anterior	0.98492		
Precio Apertura Anterior	0.98250		
PM_10	0.97593		
Middle Band Bollinger	0.95953		
Upper Band Bollinger	0.95993		
Precio Medio	0.99197		

Fuente: elaboración propia

4.5 Etapa 4: Minería de Datos

Es la etapa más importante del proceso KDD, aquí se plantea un modelo híbrido compuesto de tres técnicas de minería de datos extraídos de la literatura para predecir el precio diario de cinco acciones de la Bolsa de Valores.

Las técnicas que conforman el modelo corresponden a las revisadas en el Capítulo 3 (Red neuronal de base radial, Regresión de vectores de soporte y Redes neuronales artificiales), donde los resultados de cada uno de estas técnicas junto con las variables iniciales, serán entrada al modelo híbrido que estará compuesto por la técnica que en las pruebas de las cinco empresas, hayan obtenido los mejores resultados. La Figura 4-6 muestra el proceso seguido:

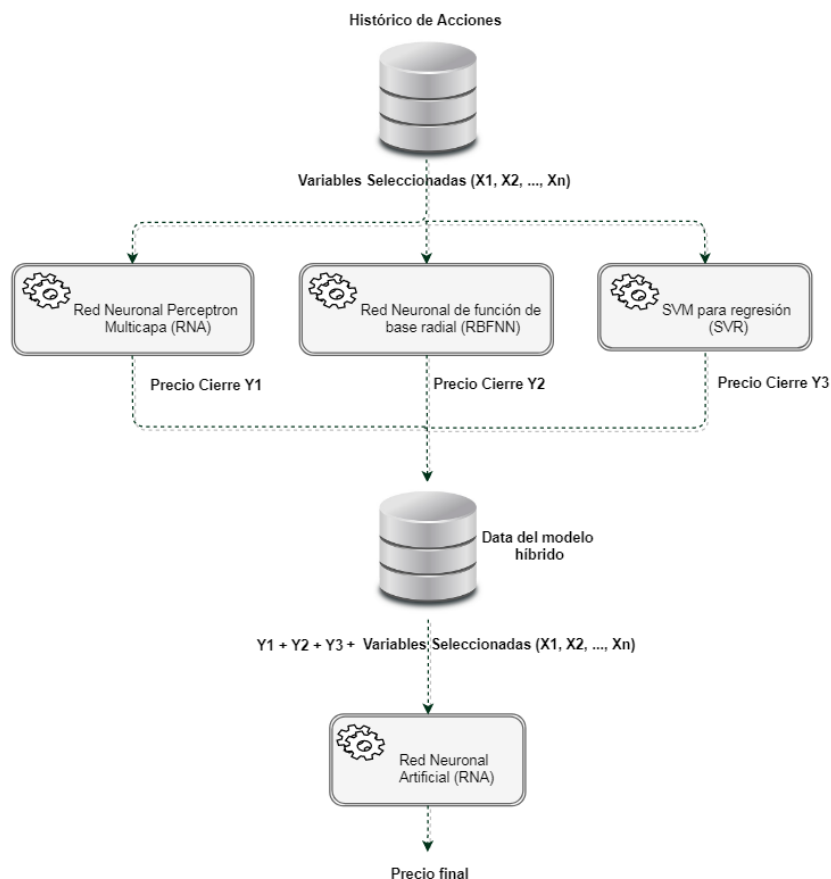


Figura 4-6 Modelo de minería de datos propuesto

Fuente: elaboración propia

La topología la Red Neuronal de base radial es dada mediante una capa de entrada que contiene las variables determinadas en la etapa 4 (Selección de Variables), una capa oculta que contiene las funciones de base radial y una neurona en la capa de salida que contiene el precio futuro de la acción.

El performance del modelo (precisión de la estimación) depende también de la elección de sus parámetros (Kao, et al., 2013), por lo que el número de funciones de base radial fue determinado mediante prueba y error.

Similar a la Red Neuronal de base radial, el performance de la técnica Regresión de Vectores de Soporte varía con la diferente selección de tres importantes parámetros: la función kernel, el parámetro de penalidad c , y el grado de la función kernel d (Ouahilal, et al., 2016), el kernel que se utilizará es de tipo polinomial debido a que es el que presentó el mejor resultado en la literatura (Ouahilal, et al., 2016), y los valores de los parámetros “ c ” y “ d ” serán hallados mediante el método ensayo y error.

Por último, la técnica redes neuronales artificiales hace uso de la red perceptrón multicapa el cual consta de una capa de entrada, una capa oculta y una capa de salida, el número de capas ocultas, momentum, épocas y tasa de aprendizaje es definido por ensayo y error, mientras que las capas de entrada son los factores que influyen en la bolsa, y la variable de salida es el precio final de una acción.

Este modelo predictor se desarrollará con la herramienta WEKA, el cual permitirá facilitar la creación del modelo con las tres técnicas planteadas, para que luego los resultados de estas técnicas sean juntadas nuevamente con las variables iniciales del modelo dando como resultado una nueva data (variables iniciales + resultado modelos); tanto para el entrenamiento como la validación. Esta nueva data servirá como entrada al modelo híbrido que está compuesto por la técnica redes neuronales artificiales por ser la técnica con mayor y mejores resultados obtenidos en las pruebas de empresas mineras.

Métricas para el desempeño del modelo

Para evaluar el desempeño de los 2 modelos planteados se hace uso de 2 métricas MAPE y RMSE, los cuales han sido elegidos por los autores de la literatura debido a la precisión en los problemas de predicción, además porque permite comparar los resultados de los modelos planteados por los autores, contra el modelo propuesto (Tabla 6 – 8). Las métricas fueron extraídas de la sección 2.4 (Resultado), Tabla 2-5.

- **El error absoluto porcentual promedio (MAPE)**, que se muestra en la ecuación es la media o promedio de los errores porcentuales absolutos de los pronósticos. El error se define como el valor real o valor observado menos el valor pronosticado (de Oliveira, et al., 2013)

Dónde:

Y: Es el valor del precio de cierre.

T: Es la fecha actual del precio de cierre.

N: Cantidad de registros.

$$MAPE = \frac{1}{n} \sum \left| \frac{\hat{Y}_{(t+1)} - Y_{(t+1)}}{Y_{(t+1)}} \right|$$

- **El error cuadrático medio (RMSE)**, representa la desviación estándar de la diferencia

entre el valor pronosticado y el valor observado. Un bajo RMSE indica que la predicción está alineado con los datos reales (de Oliveira, et al., 2013).

Dónde:

Y: Es el valor del precio de cierre.

T: Es la fecha actual del precio de cierre.

N: Cantidad de registros.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_{(t+1)} - Y_{(t+1)})^2}$$

5 Capítulo 5. Software para la predicción del precio diario de una acción basado en RNN y SVR

En este capítulo se presentan todas las etapas correspondientes a la implementación del software de predicción, comenzando por el modelo de casos de uso, especificaciones y sus respectivas interfaces, diagrama de arquitectura, modelo de base de datos y diagrama de componentes; que permitirán entender el funcionamiento del sistema.

5.1 Descripción de roles del sistema

El sistema está diseñado para poder diferenciar dos tipos de usuarios: usuario operador y usuario administrador.

1. **Usuario operador.** Es la persona encargada de realizar únicamente la predicción de la acción cuya información ha sido previamente tratada.

Funciones:

- Log in al sistema.
 - Realizar predicciones.
 - Log out del sistema.
2. **Usuario administrador.** Es la persona encargada de realizar el entrenamiento, validación para las técnicas individuales y también para el modelo híbrido, lo que permitirá obtener el modelo óptimo para hacer las predicciones.

Funciones:

- Log in del sistema.
- Tratamiento de data.
- Entrenamiento simple para técnicas individuales.
- Validación simple para técnicas individuales.
- Entrenamiento para el híbrido.
- Validación para el híbrido.
- Realizar predicciones.
- Log out del sistema.

5.2 Especificación CUS

5.2.1 CUS-Authenticación

ID:	CUS01
Caso de Uso:	Autenticación
Actor:	Operador/Administrador
Descripción:	El usuario ingresará su nombre de usuario y contraseña para que sea validado por el sistema.
Precondición:	El usuario debe estar registrado en el sistema.
Flujo Principal:	
<ol style="list-style-type: none">1. El caso de uso empieza cuando el usuario ingresa a la pantalla principal.2. El sistema le muestra la interfaz de inicio con los campos usuario y contraseña y el botón “Iniciar sesión”.3. El usuario ingresa su nombre de usuario.4. El usuario ingresa la contraseña.5. El usuario da clic en el botón “Iniciar sesión”.6. El sistema valida el nombre de usuario y contraseña.7. El sistema limpia los campos de usuario y contraseña.8. El sistema ingresa a la pantalla principal del sistema de predicción.9. El CUS termina.	
Post-condición :	El usuario ha sido validado por el sistema y puede acceder al sistema de predicción.
Flujo Alternativo:	“Usuario o contraseña incorrectos”
<ol style="list-style-type: none">1. En el paso 6, si el nombre de usuario o la contraseña no están registrados en el sistema, se mostrará el mensaje “El nombre de usuario o la contraseña son incorrectos, inténtelo de nuevo”.2. Continúa en el paso 3.	
Flujo Alternativo:	“Usuario bloqueado”
<ol style="list-style-type: none">1. En el paso 6, si la cantidad de intentos al sistemas excede a 5, el sistema bloqueará al usuario mostrando el siguiente mensaje “Ha excedido el número de intentos, el usuario ha sido bloqueado, contáctese con el administrador”.2. El CUS termina.	
Flujo Alternativo:	“Valores en blanco”
<ol style="list-style-type: none">1. En el paso 6, si el nombre de usuario o contraseña están en blanco luego de dar clic en “Iniciar sesión”, el sistema mostrará un mensaje “No es válido campos en blanco, inténtelo de nuevo”.2. Continúa en el paso 3.	

Fuente: elaboración propia

Interfaz del CUS: Autenticación



Figura 5-1. Pantalla de login

Fuente: elaboración propia

5.2.2 Tratamiento de datos

ID:	CUS02
Caso de Uso:	Tratamiento de datos
Actor:	Administrador
Descripción:	El administrador ingresará los datos de las variables que influyen en una acción minera, ya sea variables fundamentales y/o otras variables (metales asociados) y el sistema realizará la correlación de los datos ingresados para finalmente mostrar los campos seleccionados por correlación.
Precondición:	El usuario debe estar registrado en el sistema. El usuario se debe haber logueado. Los archivos a subir deberán ser de extensión “.csv”.
Flujo Principal:	<ol style="list-style-type: none">1. El caso de uso comienza cuando el administrador ingresa a la pantalla principal del sistema de predicción.2. El sistema le muestra la interfaz con varias opciones situadas en al lado lateral izquierdo: data, tratamiento, tratamiento híbrido, predecir, salir.3. El usuario selecciona la opción “Data” de la barra lateral izquierda.4. El sistema muestra la opción de ingresar el nombre de la empresa a predecir, las opciones para subir archivos (variables fundamentales y otras variables), adicional las opciones para distribuir el % en data entre entrenamiento y validación, los botones para generar la correlación y mostrar las variables seleccionadas5. El usuario ingresa el nombre de la empresa a predecir.6. El sistema valida que los valores ingresados no sean números.7. El usuario en la opción de subir archivo, selecciona “choose” y luego “upload” para seleccionar y cargar el CSV de las variables fundamentales de la empresa ingresada.8. El sistema muestra el mensaje de validación “Se subió el archivo: nombre.csv”.9. El usuario en la opción de subir archivo selecciona “choose” y luego “upload” para seleccionar y cargar el CSV de las otras variables en caso sea una acción minera. Ejemplo: data de los metales de la empresa

minera (Oro, plata, cobre, zinc).

10. El sistema muestra el mensaje de validación “Se subió el archivo: nombre.csv”.
11. El usuario selecciona el % de data de entrenamiento y validación que quiere utilizar en el modelo, moviendo y arrastrando el cursor encima de la imagen circular.
12. El sistema actualiza la información del % elegido en el cuadro de texto situado al lado derecho de la imagen (Entrenamiento X%, validación Y%).
13. El usuario da clic en el botón “Generar correlación”.
14. El sistema genera la correlación de las variables ingresadas y muestra el mensaje “Se generó la correlación”.
15. El usuario da clic en el botón “Mostrar Campos”.
16. El sistema muestra un pop up con las variables seleccionadas de la correlación.
17. El CUS termina.

Post-condición : El usuario habrá realizado el entrenamiento de los datos de archivos relacionados a una empresa.

Flujo Alternativo: “No hay archivos ‘otras variables’”

1. En el paso 9, si luego de ingresar las variables fundamentales, el usuario no ingresa “Otras variables” el CUS continúa al paso 11.

Flujo Alternativo: “Sin ingreso de nombre de empresa”

1. En el paso 5, si no ingresa ningún nombre de empresa se mostrara un mensaje “Se debe ingresar una empresa para la predicción”.
2. El CUS continúa al paso 5.

Flujo Alternativo: “Formato erróneo en el nombre de la empresa”

1. En el paso 5, si el usuario ingresa números en el nombre de la empresa, el sistema muestra el mensaje “No se aceptan números”.
2. El CUS continúa al paso 5.

Flujo Alternativo: “Formato erróneo de archivo”

1. En el paso 7 o 9, si el usuario no ingresa un formato de archivo csv, el sistema mostrará un mensaje “Solo se aceptan formatos csv”.
2. El CUS continúa al paso 7 o 9.

Flujo Alternativo: “Sin selección del % de data”

1. En el paso 11, si el usuario no selecciona un % de data para entrenamiento y validación, el sistema asume el que se muestra por defecto (70% entrenamiento, 30% validación).
2. El CUS continúa al paso 13.

Flujo Alternativo: “Sin tratamiento de datos”

1. En el paso 3, si el usuario accede a las otras opciones de la barra lateral como “Tratamiento”, “Tratamiento híbrido” o “Predicción”, el sistema le mostrará el mensaje “Es necesario subir los datos antes de realizar el tratamiento”.
2. El CUS continúa al paso 3.

Fuente: elaboración propia

Interfaz del CUS: Tratamiento de Datos

Figura 5-2. Pantalla de tratamiento de datos

Fuente: elaboración propia

5.2.3 Entrenamiento Simple

ID:	CUS03
Caso de Uso:	Entrenamiento simple
Actor:	Administrador
Descripción:	El usuario ingresa los valores de los parámetros de cada técnica seleccionada (RBFNN-SVR-MLP) y entrenará las técnicas con dichos parámetros.
Precondición:	El usuario debe estar registrado en el sistema. El usuario debe haberse logueado. El usuario debe haber subido la data y realizar el proceso de correlación.
Flujo Principal:	<ol style="list-style-type: none"> 1. El caso de uso comienza cuando el administrador ingresa a la pantalla principal del sistema de predicción. 2. El sistema le muestra la interfaz con varias opciones situadas al lado lateral izquierdo: datos, tratamiento, tratamiento híbrido, predecir, salir. 3. El usuario selecciona la opción “Tratamiento”. 4. El sistema mostrará los parámetros de cada técnica, con valores editables por defecto. RBFNN: número de funciones. SVR: parámetro C, número del exponente MLP: Capas ocultas, Tasa de aprendizaje, momentum y número de épocas. Además de los botones “Entrenar”, “Validar” y “Mejor modelo” para cada técnica. 5. El usuario pulsa el botón “Entrenar” para la técnica RBFNN. 6. El sistema muestra un mensaje indicando que ya se realizó el entrenamiento. 7. El sistema actualiza los valores del resultado de las métricas para RBFNN (MAPE, RMSE) luego del entrenamiento. 8. El usuario pulsa el botón “Entrenar” para la técnica SVR. 9. El sistema muestra un mensaje indicando que se realizó el entrenamiento. 10. El sistema actualiza los valores del resultado de las métricas para SVR (MAPE, RMSE) luego del entrenamiento. 11. El usuario pulsa el botón “Entrenar” para la técnica MLP.

-
12. El sistema muestra un mensaje indicando que se realizó el entrenamiento.
 13. El sistema actualiza los valores del resultado de las métricas para MLP (MAPE, RMSE) luego del entrenamiento.
 14. El CUS termina.

Post-condición : El usuario ha podido entrenar el modelo las técnicas individuales.

Flujo Alternativo: “Modificar los parámetros de RBFNN”

1. En el paso 4, si el usuario desea cambiar algún parámetro de las técnicas, ya sea el número de funciones para el RBFNN, puede editar ese valor.
2. El usuario ingresa un valor para el número de funciones.
3. El sistema valida el valor ingresado.
4. El usuario pulsa el botón “Entrenar” para la técnica RBFNN.
5. El sistema muestra un mensaje: “Se realizó el entrenamiento para RBFNN”.
6. El sistema actualiza los valores del resultado de las métricas para RBFNN (MAPE, RMSE) luego del entrenamiento.
7. El CUS continúa al paso 5.

Flujo Alternativo: “Modificar los parámetros de SVR”

1. En el paso 4, si el usuario desea cambiar algún parámetro de las técnicas, ya sea el parámetro c y/o exponente para el SVR, puede editar esos valores.
2. El usuario ingresa un valor para el parámetro C y/o número de exponente.
3. El sistema valida los valores ingresados.
4. El usuario pulsa el botón “Entrenar” para la técnica SVR.
5. El sistema muestra un mensaje: “Se realizó el entrenamiento para SVR”.
6. El sistema actualiza los valores del resultado de las métricas para RBFN (MAPE, RMSE) luego del entrenamiento.
1. El CUS continúa al paso 5.

Flujo Alternativo: “Modificar los parámetros de MLP”

7. En el paso 4, si el usuario desea cambiar algún parámetro de las técnicas, ya sea el número de capas ocultas, la tasa de aprendizaje, el momentum o el número de épocas para el MLP, puede editar esos valores.
8. El usuario ingresa un valor para el parámetro Capas ocultas y/o Tasa de aprendizaje y/o Momentum y/o Número de épocas.
9. El sistema valida los valores ingresados.
10. El usuario pulsa el botón “Entrenar” para la técnica MLP.
11. El sistema muestra un mensaje: “Se realizó el entrenamiento para MLP”.
12. El sistema actualiza los valores del resultado de las métricas para MLP (MAPE, RMSE) luego del entrenamiento.
13. El CUS continúa al paso 5.

Flujo Alternativo: “Mejor modelo RBFN”.

1. En el paso 7, si el usuario da clic en botón “mejor modelo” para el RBFN.
2. El sistema cargará los valores de los parámetros (número de funciones) y los resultados de las métricas (MAPE y RMSE) del modelo que obtuvo un mejor resultado.
3. El CUS continúa al paso 8.

Flujo Alternativo: “Mejor modelo SVR”.

1. En el paso 10, si el usuario da clic en botón “mejor modelo” para el SVR.
2. El sistema cargará los valores de los parámetros (Constante C y exponente) y los resultados de las métricas (MAPE y RMSE) del modelo que obtuvo un mejor resultado.
3. El CUS continúa al paso 11.

Flujo Alternativo: “Mejor modelo MLP”.

1. En el paso 10, si el usuario da clic en botón “mejor modelo” para el MLP.

2. El sistema cargará los valores de los parámetros (Capas ocultas, tasa de aprendizaje, momentum y número de épocas) y los resultados de las métricas (MAPE y RMSE) del modelo que obtuvo un mejor resultado.
3. El CUS continúa al paso 11.

Fuente: elaboración propia

Interfaz del CUS: Entrenamiento Simple

The screenshot shows a web interface for training simple models. It is divided into three main sections, each for a different model type:

- Radial Basis Function Neural Network:** Includes a field for '# Funciones de base radial' (set to 0) and buttons for 'Entrenar', 'Validar', and 'Mejor modelo'.
- Support Vector Regression:** Includes fields for 'Constante C' and 'Grado de la funcion kernel', and buttons for 'Entrenar', 'Validar', and 'Mejor modelo'.
- Multilayer Perceptron:** Includes fields for 'Capas ocultas', 'Tasa de aprendizaje', 'Momentum', and 'Numero de epocas', and buttons for 'Entrenar', 'Validar', and 'Mejor modelo'.

Each section also has a 'Métricas:' panel showing 'Entrenamiento' and 'Validacion' results for MAPE and RMSE.

Figura 5-3. Pantalla de entrenamiento simple

Fuente: elaboración propia

5.2.4 Entrenamiento Híbrido

ID:	CUS04
Caso de Uso:	Entrenamiento Híbrido
Actor:	Administrador
Descripción:	El usuario entrenará la técnica del híbrido con mejores resultados y obtendrá las métricas.
Precondición:	<p>El usuario debe estar registrado en el sistema.</p> <p>El usuario debe haber logueado.</p> <p>El usuario debe haber realizado el entrenamiento de cada una de las técnicas individuales (RBFNN, SVR, MLP).</p>
Flujo Principal:	<ol style="list-style-type: none"> 1. El caso de uso comienza cuando el administrador ingresa a la pantalla principal del sistema de predicción. 2. El sistema le muestra la interfaz con varias opciones situadas al lado lateral izquierdo: data, tratamiento, tratamiento híbrido, predecir, salir. 3. El usuario selecciona la opción "Tratamiento híbrido". 4. El sistema mostrará los parámetros de la técnica híbrida elegida (MLP), con los valores editables por defecto.

MLP: Capas ocultas, Tasa de aprendizaje, momentum y número de épocas.

Adicional los botones “Entrenar”, “Validar”, “Mejor modelo” y al lado derecho los campos no editables de los valores de las métricas (MAPE, RMSE).

5. El usuario pulsa el botón “Entrenar” para el híbrido.
6. El sistema muestra un mensaje indicando que ya se realizó el entrenamiento.
7. El sistema actualiza los valores del resultado de las métricas (MAPE, RMSE) luego del entrenamiento.
8. El CUS termina.

Post-condición : El usuario ha podido entrenar el modelo híbrido.

Flujo Alternativo: “Modificar los parámetros”

1. En el paso 4, si el usuario desea cambiar algún parámetro de la técnica ya sea el número de capas ocultas, la tasa de aprendizaje, el momentum o número de épocas, el usuario puede editar el valor.
2. El usuario ingresa un valor para las capas ocultas y/o tasa de aprendizaje y/o momentum y/o número de épocas.
3. El sistema valida los valores ingresados, mostrando mensaje “Solo se admite valores de este rango X – Y”.
4. El CUS continúa al paso 5.

Flujo Alternativo: “Seleccionar tratamiento híbrido sin haber entrenado individualmente”.

1. En el paso 3, si el usuario accede a entrenar el híbrido sin haber realizado el “Tratamiento” para cada técnica, el sistema le mostrará el mensaje “Es necesario entrenar cada técnica”.
2. El CUS continúa al paso 3.

Flujo Alternativo: “Mejor modelo Híbrido”.

1. En el paso 7, si el usuario da clic en botón “mejor modelo” para el Híbrido.
2. El sistema cargará los valores de los parámetros (Capas ocultas, tasa de aprendizaje, momentum y número de épocas) y los resultados de las métricas (MAPE y RMSE) del modelo que obtuvo un mejor resultado.
3. El CUS continúa al paso 8.

Flujo Alternativo: “Mejor modelo sin entrenar”.

1. En el paso 5, si el usuario da clic en “mejor modelo” del entrenamiento sin haber realizado el entrenamiento del híbrido, el sistema le mostrará el mensaje “Es necesario entrenar el híbrido”.
 2. El CUS continúa al paso 5.
-

Fuente: elaboración propia

Interfaz del CUS: Entrenamiento Híbrido

Modelo Híbrido

Empresa:

Modelo Híbrido

Capas ocultas:

Tasa de aprendizaje:

Momentum:

Numero de epocas:

Métricas:

Entrenamiento: MAPE: Validación: MAPE:

Entrenamiento: RMSE: Validación: RMSE:

Entrenar Validar Mejor Modelo

Figura 5-4. Pantalla de entrenamiento híbrido.

Fuente: elaboración propia

5.2.5 Validación Simple

ID:	CUS05
Caso de Uso:	Validación simple
Actor:	Administrador
Descripción:	El usuario luego de haber obtenido el mejor modelo de entrenamiento, realiza la validación para cada modelo y muestra los resultados de las métricas.
Precondición:	El usuario debe estar registrado en el sistema. El usuario debe haberse logueado. El usuario debe haber realizado el entrenamiento.
Flujo Principal:	<ol style="list-style-type: none"> 1. En el caso uso comienza cuando el administrador ingresa a la pantalla principal del sistema de predicción 2. El sistema le muestra la interfaz con varias opciones situadas al lado lateral izquierdo: data, tratamiento, tratamiento híbrido, predecir, salir. 3. El usuario selecciona la opción “Tratamiento”. 4. El sistema mostrará los parámetros de cada técnica, con valores editables por defecto. RBFN: número de funciones. SVR: parámetro C, número del exponente MLP: Capas ocultas, Tasa de aprendizaje, momentum y número de épocas. Además de los botones “Entrenar”, “Validar” y “Mejor modelo” para cada técnica. 5. El usuario pulsa el botón “Validar” para la técnica RBFNN. 6. El sistema muestra un mensaje indicando que se realizó la validación. 7. El sistema actualiza los valores del resultado de las métricas para RBFNN (MAPE, RMSE) luego de la validación. 8. El usuario pulsa el botón “Validar” para la técnica SVR. 9. El sistema muestra un mensaje indicando que se realizó la validación. 10. El sistema actualiza los valores del resultado de las métricas para SVR (MAPE, RMSE) luego de la validación. 11. El usuario pulsa el botón “Validar” para la técnica MLP. 12. El sistema muestra un mensaje indicando que se realizó la validación. 13. El sistema actualiza los valores del resultado de las métricas para MLP (MAPE, RMSE) luego de la validación. 14. El CUS termina.
Post-condición :	El usuario ha podido validar las técnicas individualmente.
Flujo Alternativo:	<p>“Modificar los parámetros de RBFNN”</p> <ol style="list-style-type: none"> 1. En el paso 4, si el usuario desea cambiar algún parámetro de las técnicas, ya sea el número de funciones para el RBFNN, puede editar ese valor. 2. El usuario ingresa un valor para el número de funciones. 3. El sistema valida el valor ingresado. 4. El usuario pulsa el botón “Entrenar” para la técnica RBFNN. 5. El sistema muestra un mensaje indicando que ya se realizó el entrenamiento. 6. El sistema actualiza los valores del resultado de las métricas para RBFNN (MAPE, RMSE) luego del entrenamiento. 7. El CUS continúa al paso 5. <p>“Modificar los parámetros de SVR”</p> <ol style="list-style-type: none"> 1. En el paso 4, si el usuario desea cambiar algún parámetro de las técnicas, ya sea el parámetro c y/o exponente para el SVR, puede editar esos valores. 2. El usuario ingresa un valor para el parámetro C y/o número de exponente. 3. El sistema valida los valores ingresados.

-
4. El usuario pulsa el botón “Entrenar” para la técnica SVR.
 5. El usuario el botón “Entrenar” para la técnica SVR.
 6. El sistema muestra un mensaje: “Se realizó el entrenamiento para SVR”.
 7. El sistema actualiza los valores del resultado de las métricas para RBFN (MAPE, RMSE) luego del entrenamiento.
 8. El CUS continúa al paso 5.

Flujo Alternativo: “Modificar los parámetros de MLP”

1. En el paso 4, si el usuario desea cambiar algún parámetro de las técnicas, ya sea el número de capas ocultas, la tasa de aprendizaje, el momentum o el número de épocas para el MLP, puede editar esos valores.
2. El usuario ingresa un valor para el parámetro Capas ocultas y/o Tasa de aprendizaje y/o Momentum y/o Número de épocas.
3. El sistema valida los valores ingresados.
4. El usuario pulsa el botón “Entrenar” para la técnica MLP.
5. El sistema muestra un mensaje: “Se realizó el entrenamiento para MLP”.
6. El sistema actualiza los valores del resultado de las métricas para MLP (MAPE, RMSE) luego del entrenamiento.
7. El CUS continúa al paso 5.

Flujo Alternativo: “Mejor modelo RBFN”.

1. En el paso 5, si el usuario da clic en botón “mejor modelo” del entrenamiento.
2. El sistema cargará los valores de los parámetros (número de funciones) y los resultados de las métricas (MAPE y RMSE) donde el modelo obtuvo un mejor resultado.
3. El CUS continúa al paso 5.

Flujo Alternativo: “Mejor modelo SVR”.

1. En el paso 5, si el usuario da clic en botón “mejor modelo” del entrenamiento.
2. El sistema cargará los valores de los parámetros (Constante C y exponente) y los resultados de las métricas (MAPE y RMSE) donde el modelo obtuvo un mejor resultado.
3. El CUS continúa al paso 5.

Flujo Alternativo: “Mejor modelo MLP”.

1. En el paso 5, si el usuario da clic en botón “mejor modelo” del entrenamiento.
2. El sistema cargará los valores de los parámetros (Capas ocultas, tasa de aprendizaje, momentum y número de épocas) y los resultados de las métricas (MAPE y RMSE) del modelo que obtuvo un mejor resultado.
3. El CUS continúa al paso 5.

Fuente: elaboración propia

Interfaz del CUS: Validación Simple

Post-condición :	El usuario ha podido validar el modelo de predicción.
Flujo Alternativo:	<p>“Modificar los parámetros del híbrido”</p> <ol style="list-style-type: none"> 1. En el paso 5, si el usuario desea cambiar algún parámetro de las técnicas, ya sea las capas ocultas, tasa de aprendizaje, momentum o número de épocas para el SVR, puede editar esos valores. 2. El usuario pulsa el botón “Entrenar” para el híbrido. 3. El sistema muestra un mensaje indicando que se realizó el entrenamiento. 4. El sistema actualiza los valores del resultado de las métricas para el híbrido (MAPE, RMSE) luego de la validación. 5. El CUS continúa al paso 6.
Flujo Alternativo:	<p>“Mejor modelo Híbrido”.</p> <ol style="list-style-type: none"> 1. En el paso 5, si el usuario da clic en botón “mejor modelo” del entrenamiento. 2. El sistema cargará los valores de los parámetros (Capas ocultas, tasa de aprendizaje, momentum y número de épocas) y los resultados de las métricas (MAPE y RMSE) donde el modelo obtuvo un mejor resultado. 3. El CUS continúa al paso 5.
Flujo Alternativo:	<p>“Seleccionar tratamiento híbrido sin haber entrenado individualmente”.</p> <ol style="list-style-type: none"> 1. En el paso 3, si el usuario accede a entrenar el híbrido sin haber realizado el “Tratamiento” para cada técnica, el sistema le mostrará el mensaje “Es necesario entrenar las técnicas”. 2. El CUS continúa al paso 3.
Flujo Alternativo:	<p>“Mejor modelo sin entrenar”.</p> <ol style="list-style-type: none"> 1. En el paso 6, si el usuario da clic en “mejor modelo” del entrenamiento sin haber realizado el entrenamiento para cada la técnica, el sistema le mostrará el mensaje “Es necesario entrenar el híbrido”. 2. El CUS continúa al paso 5.

Fuente: elaboración propia

Interfaz del CUS: Validación Híbrido

Modelo Híbrido

Empresa:

Modelo Híbrido

Capas ocultas:

Tasa de aprendizaje:

Momentum:

Numero de epocas:

Métricas:

Entrenamiento:

MAPE:

RMSE:

Validacion:

MAPE:

RMSE:

Entrenar

Validar

Mejor Modelo

Figura 5-6. Pantalla de validación híbrido

Fuente: elaboración propia

5.2.7 Predecir Precio

ID:	CUS07
Caso de Uso:	Predecir Precio
Actor:	Administrador u operador
Descripción:	El usuario ingresará los datos de la empresa que desea predecir (csv de las variables fundamentales y otras variables) y al pulsar el botón “predecir” el sistema predecirá el precio final.
Precondición:	<p>El usuario debe estar registrado en el sistema.</p> <p>El usuario debe haber realizado el entrenamiento y validación de las técnicas individuales.</p> <p>El usuario debe haber realizado el entrenamiento y validación para el modelo híbrido.</p> <p>El archivo csv de “otras variables” la 4ta columna debe hacer referencia al precio de cierre de la acción.</p>
Flujo Principal:	<ol style="list-style-type: none"> 1. El caso de uso empieza cuando el usuario ingresa a la pantalla principal. 2. El sistema le muestra la interfaz con varias opciones situadas en el lado lateral izquierdo: data, tratamiento, tratamiento híbrido, predecir, salir. 3. El usuario selecciona la pestaña Predecir. 4. El sistema muestra la opción de ingresar el nombre de la empresa a predecir, las opciones para subir archivos (variables fundamentales y otras variables), adicional las los campos “precio cierre”, “fecha” y el botón “Predecir”. 5. El usuario ingresa el nombre de la empresa a predecir. 6. El sistema valida que los valores ingresados no sean números. 7. El usuario selecciona “choose” y luego “upload” para seleccionar y carga el CSV de las variables fundamentales de la empresa ingresada. 8. El sistema muestra el mensaje de validación “Se subió el archivo: nombre.csv”. 9. El usuario selecciona “choose” y luego “upload” para seleccionar y cargar los CSVs de las otras variables en caso sea una acción minera. Ejemplo: data de los metales de la empresa minera (Oro, plata, cobre, zinc). 10. El sistema muestra el mensaje de validación “Se subió el archivo: nombre.csv”. 11. El sistema carga los valores en las etiquetas: Precio cierre y fecha. 12. El usuario pulsa el botón “Predecir”. 13. El sistema muestra una ventana con el precio del día siguiente de la acción de la empresa ingresada. 14. El CUS termina.
Post-condición :	El usuario ha podido predecir el precio de una acción.
Flujo Alterno:	<p>“Sin ingreso de nombre de empresa”</p> <ol style="list-style-type: none"> 1. En el paso 5, si no ingresa ningún nombre de empresa se mostrara un mensaje “Se debe ingresar una empresa para la predicción”. 2. El CUS continúa al paso 5.
Flujo Alterno:	<p>“No hay archivos ‘otras variables’”</p> <ol style="list-style-type: none"> 1. En el paso 9, si luego de ingresar las variables fundamentales, el usuario no ingresa “Otras variables” el CUS continúa al paso 11.

Flujo Alternativo:	“Formato erróneo en el nombre de la empresa”
<ol style="list-style-type: none"> 1. En el paso 5, si el usuario ingresa números en el nombre de la empresa, el sistema muestra el mensaje “No se aceptan números”. 2. El CUS continúa al paso 5. 	
Flujo Alternativo:	“Formato erróneo de archivo”
<ol style="list-style-type: none"> 1. Si en el 7 o 9, el usuario no ingresa un formato de archivo csv, el sistema mostrará un mensaje “Solo se aceptan formatos csv”. 2. El CUS continúa al paso 7 o 9. 	

Fuente: elaboración propia

Interfaz del CUS: Predecir precio

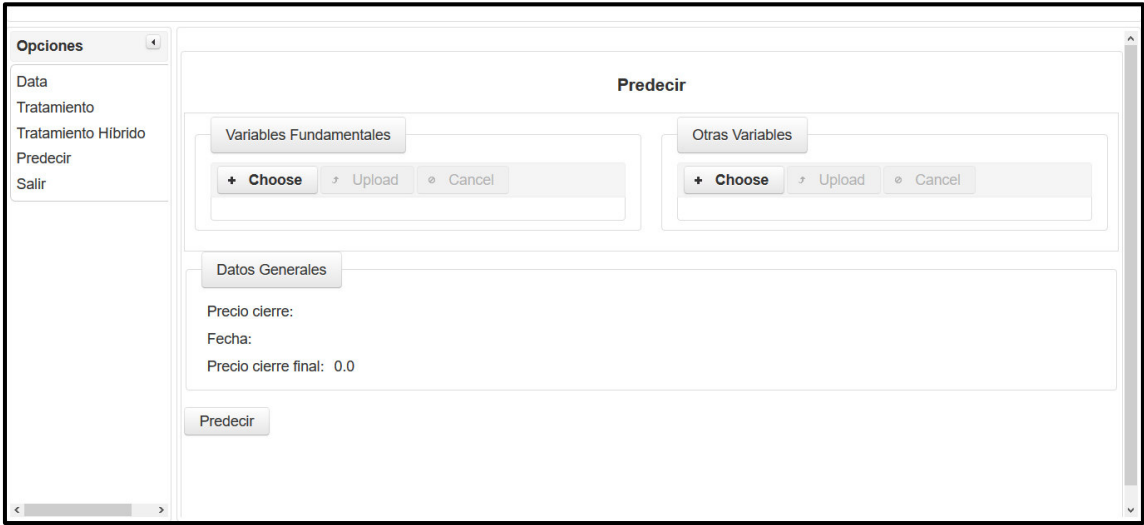


Figura 5-7. Pantalla de predecir precio

Fuente: elaboración propia

5.2.8 Log out

ID:	CUS08
Caso de Uso:	Logout
Actor:	Operador/Administrador
Descripción:	El usuario cierra la sesión del sistema.
Precondición:	El usuario debe estar registrado en el sistema. El usuario debe haber logueado.
Flujo Principal:	
<ol style="list-style-type: none"> 1. El caso de uso empieza cuando el usuario ingresa a la pantalla principal 2. El sistema le muestra la interfaz con varias opciones situadas al lado lateral izquierdo: data, tratamiento, tratamiento híbrido, predecir, salir. 3. El usuario hace clic en el botón “Salir”. 4. El CUS termina. 	

Post-condición :	El usuario ha cerrado la sesión del sistema, en caso haya realizado entrenamiento o validación, los modelos han quedado guardado.
-------------------------	---

Fuente: elaboración propia

5.3 Diagrama de Arquitectura

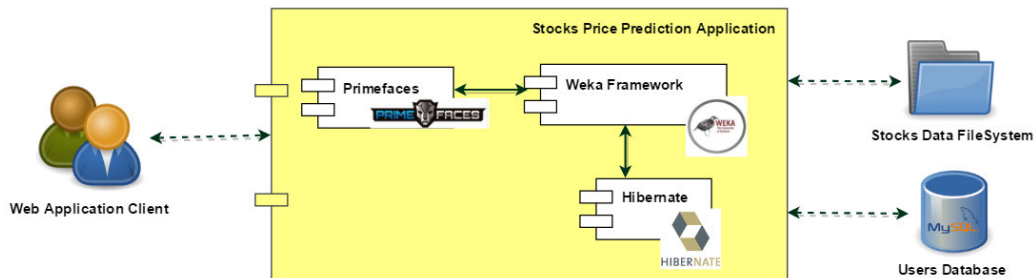


Figura 5-8. Arquitectura del sistema

Fuente: elaboración propia

La aplicación desarrollada está basada en una arquitectura MVC, utilizando el framework primefaces para la capa de la vista, Weka para el procesamiento de los datos (formación de los modelos y predicción) y hibernate para el acceso a la base de datos (modelo). Adicionalmente, se cuenta con dos repositorios externos: una base de datos Mysql la cual se encarga de mantener los usuarios del sistema, y un Filesystem dentro del servidor, en el cual se almacena las diferentes transformaciones internas de la data histórica.

5.4 Diagrama de Base de datos

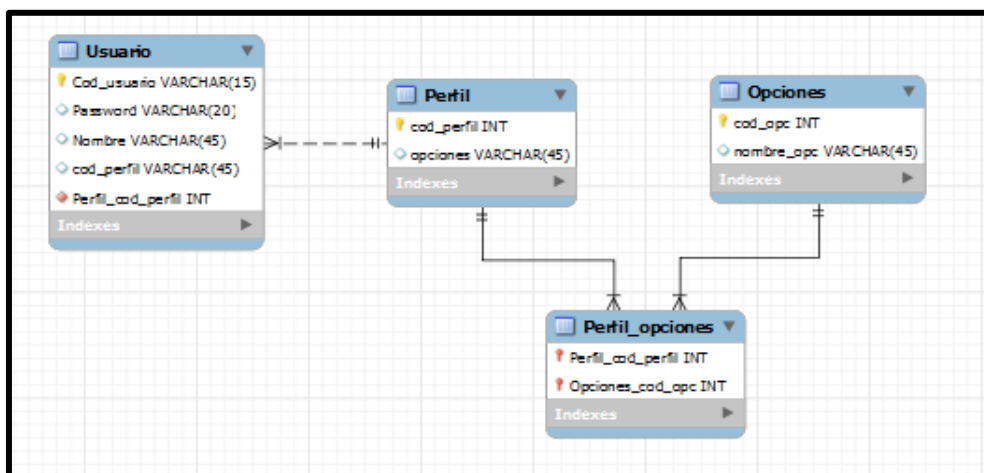


Figura 5-9. Diagrama de datos

Fuente: elaboración propia

La base de datos está orientada al registro de usuario, donde se definen tres tablas principales: Usuario, el cual registra los datos básicos del usuario (nombre, password, código del usuario), la tabla “perfil”, que se relaciona con la tabla “opciones” para obtener los perfiles de los usuarios (administrador, usuario) y las opciones que le corresponden.

5.5 Diagrama de componentes

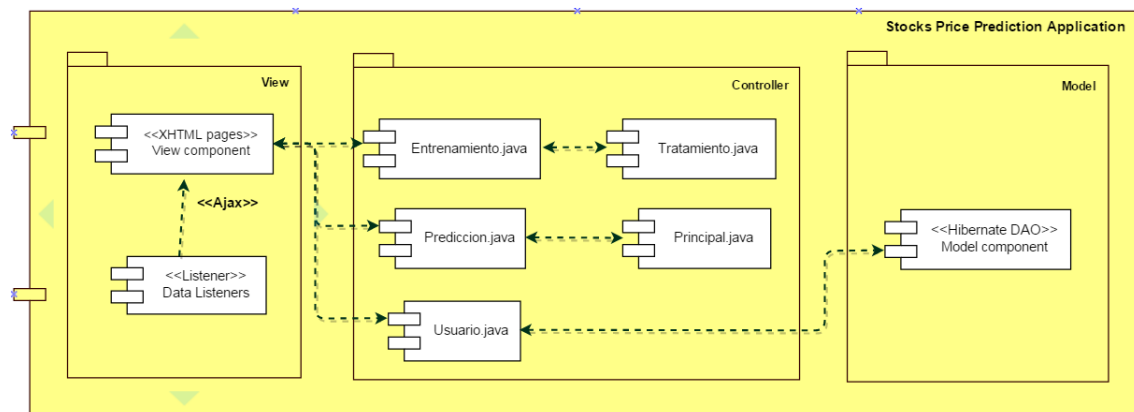


Figura 5-10. Diagrama de componentes

Fuente: elaboración propia

Los componentes utilizados en la construcción de la aplicación se observan en la Figura 5-10:

- Se tiene un conjunto de páginas XHTML que son actualizadas asíncronamente a través de los listener con peticiones Ajax.
- En el controlador se tienen las clases que contienen la lógica para el tratamiento de la data, entrenamiento y predicción.
- En el modelo se tienen todos los DAOs necesario para acceder a la Base de datos.

6 Capítulo 6. Pruebas y validaciones

Como se observa en la presente tesis, la predicción de precios de acciones en la bolsa de valores es un tema de investigación muy recurrente en el área de machine learning, sin embargo, no se han encontrado estudios que se hayan enfocado específicamente a empresas del sector minero, por lo que para realizar la validación, se evaluó la efectividad del modelo propuesto en cinco casos de estudio. Adicional a ello, se evaluó cada uno de los conjunto de datos presentados en la literatura (pertenecientes a diferentes sectores), y se comparó los resultados, con los obtenidos por el modelo propuesto, con el fin de demostrar la mejora en los resultados utilizando el modelo planteado.

6.1 Conjunto de datos de los autores

Se ha considerado datasets de cinco empresas mineras en el periodo de 3 años (29 de Mayo del 2014 al 29 de Mayo del 2017), la información de las variables fundamentales de cada empresa minera se obtuvo de la página *finance.yahoo.com*, mientras que los precios de los minerales asociados a cada empresa, así como los índices de las bolsas de valores y el dólar, se encontró en la plataforma *investing.com*. La siguiente tabla muestra la división de la data de entrenamiento y validación para cada una de las empresas mineras.

Tabla 6-1 *Cantidad de registros de las 5 empresas mineras*

División	Cantidad de registros
Buenaventura(BVN)	755
Barrick Gold Corporation(ABX)	777
Billiton Limited(BHP)	756
Fortuna Silver Mines(FSM)	756
Southern Copper(SCCO)	755

Fuente: elaboración propia

6.2 Pre procesamiento

Luego de la selección de datos se realizó un pre procesamiento del dataset, utilizando la técnica del coeficiente de correlación de Pearson, con el objetivo de tener un dataset confiable debido a que se encontraron registros incongruentes. El valor del coeficiente de correlación se tomó como referencia en base al autor Wang et al. (2016), quien utilizó 0.3428 como coeficiente de Pearson, pero realizando las pruebas y comparando con otro coeficiente propuesto 0.8, se concluyó que mientras mayor es el coeficiente de correlación, mejor es el

resultado. Para la separación de los datos en entrenamiento y validación se analizó las distribuciones utilizadas en la literatura considerando los mejores resultados, por ello se comparó 2 distribuciones de datos 60/40, 70/30 las cuales fueron usadas por Mitra et al (2015) y Ouahilal et al (2016) respectivamente, contra la distribución propuesta 90/10. La Tabla 6-3 muestra la comparación de las pruebas de las 3 distribuciones de datos más utilizadas (60/40, 70/30, 90/10) con los dos coeficientes de correlación (0.3428, 0.8) aplicados al dataset de una de las empresas mineras (BVN). Los resultados finales para las 3 técnicas (RBFN, SVR, RNN) y el híbrido, muestran que los mejores resultados se obtuvieron, teniendo al coeficiente de correlación es 0.8 y la distribución 90/10, 90% para entrenamiento y 10% para validación.

Tabla 6-2 *Resultados de las pruebas con diferentes configuraciones*

Datos	Coficiente	RBFN	SVR	RNN	Híbrido
60-40	0.3428	5.873	2.980	3.173	3.043
	0.8	2.839	2.528	2.631	2.538
70-30	0.3428	6.152	2.515	2.459	2.487
	0.8	2.958	2.424	2.437	2.416
90-10	0.3428	2.021	1.991	1.913	1.970
	0.8	1.731	1.719	1.671	1.720
Resultados:		1.731	1.719	1.671	1.720

Fuente: elaboración propia

Vale la pena resaltar que, en una primera instancia, algunos históricos descargados presentaban data inconsistente, mostrando como precio de cierre de un determinado día, un valor fuera del rango [mínimo, máximo] especificado en el mismo registro, esto se solucionó buscando la misma data en otra fuente de datos (Google finance) y validando que sea consistente, adicional a ello se eliminaron los registros nulos que afectarían el dataset si no eran identificados y borrados.

6.3 Selección de parámetros

Para probar el modelo híbrido, primero se debe entrenar cada modelo específico por separado, por lo que se ha extraído de la literatura los valores de los parámetros que ofrecieron mejores resultados para las técnicas utilizadas.

Radial Basis Function Network

Tabla 6-3 *Parámetros de RBFNN*

Parámetros	Valores	Autores
------------	---------	---------

Número de funciones	[2,3,4,5,6,7,8,9,10,12,14,16,18,20,25,30,35,40,45,50]	Guo, et al. (2015)
----------------------------	---	--------------------

Fuente: elaboración propia

Support Vector Regression

Tabla 6-4 *Parámetros de SVR.*

Parámetros	Valores	Autores
Grado de la función Kernel	1, 2	Propuesto
	[1, 2, 3,..10, 20..100]	Propuesto
Parámetro de regularización	$2^{-1}, 2^1, 2^3, 2^5, 2^7, 2^9$	Kao, et al. (2013)
	275	Ouahilal, et al. (2016)
Kernel	Polinomial	Ouahilal, et al. (2016)

Fuente: elaboración propia

Red Neuronal Perceptrón Multicapa

Para el modelo de Red neuronal perceptrón multicapa los parámetros fueron elegidos tomando como referencia la literatura, agregando además parámetros nuevos propuestos. Además, como las tasas de aprendizaje más bajas tendían a dar los mejores resultados de red (Chauvin y Rumelhart, 1995) se propuso la tasa 0.004.

Tabla 6-5 *Parámetros de la red neuronal*

Parámetros	Valores	Autores
Momentum	0.4	Mitra y Wang (2015)
Epocas	1000, 10000	Mitra y Wang (2015)
		Jonathan L. Ticknor (2013)
Learning rate	0.1,0.04,0.004	Dai, et al. (2012)
		Lu (2010)
		Ticknor (2013)
Nro. De neuronas	5,6,10,13,90	Mitra y Wang (2015)
		Lu (2010)

Fuente: elaboración propia

Estos valores significan un punto de partida al momento de realizar las pruebas, debido que,

por lo general se prueban valores adicionales para poder encontrar los mejores resultados.

6.4 Resultados de Pruebas

Se realizó una calibración manual y sistemática de los parámetros para los tres modelos usados, partiendo de los mejores valores dados en la literatura (Tabla 6-3, Tabla 6-4 y Tabla 6-5). Los resultados de todas las pruebas realizadas se encuentran en el Anexo 3.

Luego de realizar las pruebas se obtuvo que los mejores resultados obtenidos para cada técnica se logró realizando las siguientes configuraciones.

Tabla 6-6 *Mejor configuración encontrada para los casos de estudio*

Técnica	Parámetro	Buena Ventura	Barrick Gold Corporation	Billiton Limited	Fortuna Silver Mines	Southern Copper
		(BVN)	(ABX)	(BHP)	(FSM)	(SCCO)
RBFNN	Grado	5	4	4	4	2
SVR	Grado	1	1	1	1	1
	C	2	80	80	0.5	0.5
MLP	Momentum	0.4	0.2	0.2	0.2	0.1
	Épocas	1000	1000	10000	1000	1000
	Tasa de Aprendizaje	0.02	0.01	0.04	0.004	0.004
	Neuronas	5	5	10	65	6
HÍBRIDO	Momentum	0.2	0.4	0.2	0.2	0.2
	Épocas	1000	1000	10000	1000	1000
	Tasa de Aprendizaje	0.04	0.004	0.1	0.004	0.004
	Neuronas	100	100	10	90	13

Fuente: elaboración propia

Luego de ello, los resultados obtenidos tanto para las técnicas como el híbrido se muestran en la Tabla 6-7, donde se observa que el MAPE promedio del híbrido para las 5 empresas mineras fue de 1.631% de error y los menores resultados por cada técnica son sombreados en rojo, concluyendo que en 3 de los 5 casos Redes neuronales artificiales obtuvo mejores resultados.

Tabla 6-7 *Resultados alcanzados en los casos de estudio*

Caso de Estudio	Resultados Evaluación				Mejor valor
	RBFNN	SVR	MLP	HÍBRIDO	
BVN	1.731	1.719	1.663	1.666	1.663
ABX	1.627	1.564	1.485	1.470	1.470
BHP	1.385	1.386	1.382	1.375	1.375
FSM	2.726	2.517	2.576	2.567	2.517
SCCO	1.014	1.031	1.005	0.998	0.998
Promedio				1.615	1.605

Fuente: elaboración propia

Con esto se concluye que si bien, no es posible comparar con investigaciones de otros autores enfocados en el sector minero por la falta de estudios realizados, sí es posible comparar con sectores más cercanos como el petrolero, donde el autor de Oliveira et al. (2013), obtuvieron un error de 5.450% mientras que el modelo propuesto obtuvo 1.615% superando los resultados de la literatura. Adicional a ello, con el fin de evidenciar que el modelo no solo es mejor en el sector minero, se identificó todos los papers donde las predicciones se enfocaban en acciones y no índice, para que así utilizando la misma data de los autores y aplicando el modelo propuesto los resultados superen a los planteados.

La tabla siguiente muestra el resumen de las pruebas realizadas en cada caso de la literatura, de ello se observa que, en 9 de los 17 casos probados, el modelo superó a los resultados del autor y además a ello, el promedio de error del híbrido propuesto es 0.873 menor a 1.103 que es el resultado promedio de los autores.

		HÍBRIDO											Resultados Evaluación						
Referencia	Caso de estudio	RBFNN	SVR		MLP			Neuro	Momen	Épocas	Learning rate	Neuronas	Rbfnn	Svr	Mlp	Híbrido	Resultad o Paper	¿Mejoró?	
		Grado	Grado	C	Momentu m	Épocas	Learning rate	nas	tum										
Ouahilal, et al (2016)	Maroc Telecom	5	1	20	0.4	10000	0.004	5	0.4	10000	0.004	5	0.543	0.535	0.554	0.566	0.067	NO	
Bebarta, et al. (2015)	IBM	3	1	80	0.4	10000	0.004	100	0.4	10000	0.004	100	2.847	1.014	1.037	1.051	1.382	SI	
	MSFT	10	1	20	0.4	1000	0.1	90	0.4	10000	0.04	10	0.642	0.676	0.700	0.648	0.970	SI	
	Coke	4	1	1	0.4	1000	0.001	5	0.4	1000	0.001	5	0.567	0.567	0.558	0.567	0.490	NO	
	Exxon	2	1	10	0.4	1000	0.004	100	0.4	10000	0.004	100	1.214	1.078	1.099	1.068	0.790	NO	
	IBM	3	1	80	0.4	10000	0.004	100	0.4	10000	0.004	100	0.732	0.744	0.731	0.729	0.740	SI	
Mitra y Wang (2015)	PG	4	1	90	0.4	1000	0.04	10	0.4	10000	0.1	6	0.838	0.650	0.664	0.665	0.560	NO	
	DD	4	1	40	0.2	10000	0.1	90	0.4	1000	0.1	5	0.849	0.859	0.835	0.845	0.480	NO	
	JPM	10	1	20	0.4	10000	0.1	5	0.4	1000	0.02	5	0.659	0.646	0.654	0.655	1.040	SI	
	JNJ	10	1	20	0.4	1000	0.004	65	0.4	1000	0.004	65	0.674	0.671	0.680	0.677	0.610	NO	
Oliveira, et al. (2013)	PETR4	2	1	2	0.4	1000	0.04	10	0.4	1000	0.04	10	1.503	1.375	1.344	1.349	5.450	SI	
Wei, et al. (2013)	Microsoft Corporation	4	1	1	0.4	1000	0.004	5	0.4	10000	0.001	5	1.010	0.963	0.971	0.968	1.050	SI	
	Goldman Sachs Group	3	1	1	0.4	1000	0.004	65	0.4	10000	0.001	65	1.216	1.164	1.201	1.207	1.320	SI	
	IBM	7	1	4	0.4	1000	0.04	5	0.4	1000	0.01	5	0.624	0.637	0.624	0.599	0.630	SI	
Hadavandi, et al. (2015)	DELL	4	1	9	0.4	10000	0.04	10	0.4	1000	0.001	1000	4.639	0.872	0.988	0.924	0.530	NO	
	British airlines	3	1	7	0.4	10000	0.004	50	0.4	1000	0.004	50	0.967	0.920	0.995	0.990	1.410	SI	
	Ryanair airlines	2	1	1	0.1	1000	0.002	3	0.1	1000	0.002	3	1.353	1.369	1.316	1.327	1.240	NO	
														Promedio			0.873	1.103	SI (9/17)

Tabla 6-8 Comparación de la evaluación de los resultados de la literatura con el modelo propuesto.

Como se observa en la Tabla 6-8, en algunas ocasiones los modelos específicos tuvieron mejores resultados que el híbrido, y esto es debido a que el híbrido está basado en el modelo red neuronal de perceptrón multicapa, que posiblemente no tuvo buenos resultados como el modelo específico, y esto se generalizó al híbrido.

6.5 Experimentos para evaluar el modelo

Los resultados experimentales de predicción se realizaron sobre las cinco empresas mineras considerando un intervalo de 30 días para poder visualizar la efectividad del modelo propuesto al momento de predecir el precio de la acción.

Buenaventura (BVN)

Se realizó la predicción del precio futuro de la empresa Buenaventura dentro del periodo del 12 de Abril del 2017 al 24 de Mayo del 2017 (considerando también información de los 30 días anteriores para calcular las variables técnicas), y se comparó con los valores reales del día siguiente, los resultados se muestran en la Tabla 6-10. Esta empresa opera en la bolsa de valores de New York, así como también en la bolsa de valores de Lima.

La Tabla 6-9 posee cuatro columnas, en la cual, la primera indica la fecha del registro en evaluación, la columna “precio de predicción” indica la salida del modelo híbrido, la columna “Precio real” es el precio del día siguiente, y en cuarta columna se puede observar el error de cada registro obtenido como el valor absoluto de la diferencia del precio real menos el precio de predicción, sobre el mismo precio real, permitiendo calcular finalmente el MAPE en base a la suma ponderada de todos los errores.

Tabla 6-9 *Precio predicho vs precio real - Buenaventura*

Fecha	Precio Predicción	Precio Real	Error Porcentual
12/04/2017	12.065	12.360	2.386
13/04/2017	12.357	12.350	0.059
17/04/2017	12.337	12.630	2.318
18/04/2017	12.585	12.260	2.652
19/04/2017	12.272	12.310	0.310
20/04/2017	12.254	12.200	0.439
21/04/2017	12.145	11.960	1.543
24/04/2017	11.974	11.780	1.648
25/04/2017	11.758	11.980	1.853
26/04/2017	11.898	11.600	2.566
27/04/2017	11.564	12.010	3.711

28/04/2017	11.904	11.610	2.529
1/05/2017	11.581	11.770	1.603
2/05/2017	11.693	11.950	2.154
3/05/2017	11.888	11.750	1.177
4/05/2017	11.688	12.420	5.894
5/05/2017	12.298	12.490	1.541
8/05/2017	12.367	12.310	0.464
9/05/2017	12.240	12.260	0.160
10/05/2017	12.184	12.530	2.765
11/05/2017	12.426	12.610	1.456
12/05/2017	12.494	12.550	0.446
15/05/2017	12.470	12.470	0.000
16/05/2017	12.400	12.680	2.205
17/05/2017	12.566	12.090	3.939
18/05/2017	12.106	12.350	1.979
19/05/2017	12.255	12.500	1.956
22/05/2017	12.400	12.000	3.330
23/05/2017	12.012	12.060	0.397
24/05/2017	11.984	12.190	1.687
MAPE:			1.839

Fuente: elaboración propia

En la Figura 6-1 se muestra la comparativa del precio real vs el precio predicho, donde se puede observar que a pesar de que Buenaventura es una empresa muy volátil en cuanto al precio de sus acciones (llega a descender hasta 11.6 y a ascender hasta 12.68 en tan solo un mes), el modelo se adapta muy bien a este caso.




Figura 6-1. Precio predicho vs precio real – Buenaventura

Fuente: elaboración propia

Fortuna Silver Mines (FSM)

Fortuna Silver mines tiene minas en Perú, en el departamento de Arequipa, los cuales se dedica a la explotación de plata, plomo y zinc. Adicionalmente, tiene sede en Oaxaca - México y Argentina, donde se encargan de la explotación de oro y plata. Esta empresa opera en la bolsa de valores de New York, pero no en la bolsa de valores de Lima.

La Tabla 6-10 muestra los resultados de la evaluación del modelo propuesto para FSM en el periodo de tiempo desde el 12 de Abril del 2017 al 24 de Mayo del 2017(considerando también información de los 30 días anteriores para calcular las variables técnicas), mientras que la Figura 6-2 muestra estos mismos resultados en una gráfica fecha vs precio.

De la Figura 6-2 se puede observar la proximidad del precio predicho por el modelo al precio real del día siguiente.

Tabla 6-10 *Precio predicho vs precio real – Fortuna Silver Mines*

Fecha	Precio Predicción	Precio Real	Error Porcentual
12/04/2017	5.372	5.230	2.721
13/04/2017	5.248	5.150	1.912
17/04/2017	5.133	5.150	0.323
18/04/2017	5.145	4.940	4.152
19/04/2017	4.935	5.020	1.694
20/04/2017	4.994	5.000	0.115
21/04/2017	5.006	4.820	3.864
24/04/2017	4.841	4.620	4.777
25/04/2017	4.605	4.610	0.108
26/04/2017	4.594	4.470	2.783
27/04/2017	4.484	4.610	2.724
28/04/2017	4.602	4.450	3.409
1/05/2017	4.475	4.420	1.246
2/05/2017	4.465	4.370	2.172
3/05/2017	4.416	4.160	6.148
4/05/2017	4.222	4.250	0.647
5/05/2017	4.273	4.250	0.530
8/05/2017	4.246	4.210	0.860
9/05/2017	4.212	4.320	2.506
10/05/2017	4.319	4.430	2.504
11/05/2017	4.433	4.430	0.060
12/05/2017	4.452	4.550	2.151
15/05/2017	4.532	4.530	0.045

16/05/2017	4.531	4.720	4.005
17/05/2017	4.733	4.540	4.259
18/05/2017	4.586	4.530	1.247
19/05/2017	4.568	4.670	2.186
22/05/2017	4.656	4.630	0.562
23/05/2017	4.622	4.370	5.767
24/05/2017	4.397	4.740	7.241
MAPE			2.424

Fuente: elaboración propia




Figure 6-2. Precio predicho vs precio real – Fortuna Silver Mines

Fuente: elaboración propia

Southern Copper (SCC)

Southern es una empresa con capital peruano que posee la mayor reserva de cobre en la industria. Southern produce, además de cobre, zinc, plomo, carbón y plata. Todas sus minas se encuentran en los países Perú y México y tienen actividades de exploración en Chile. Esta empresa opera en la bolsa de valores de New York, así como también en la bolsa de valores de Lima.

Buenaventura, Fortuna Silver Mines y Southern Copper fueron elegidas como casos de estudio debido a que eran las únicas tres empresas mineras que poseían capital peruano y operaban en la bolsa de valores de New York.

La *tabla 6-12* muestran los resultados de la evaluación del modelo propuesto para SCC en

el periodo de tiempo desde el 12 de Abril del 2017 al 24 de Mayo del 2017(considerando también información de los 30 días anteriores para calcular las variables técnicas), mientras que el *gráfico 6-3* muestran estos mismos resultados en una gráfica fecha vs precio.

Tabla 6-11 *Precio predicho vs precio real – Southern Copper*

Fecha	Precio Predicción	Precio Real	Error Porcentual
12/04/2017	35.412	34.970	1.264
13/04/2017	35.158	35.440	0.795
17/04/2017	35.440	34.960	1.374
18/04/2017	34.980	34.900	0.229
19/04/2017	35.075	35.390	0.889
20/04/2017	35.479	35.280	0.565
21/04/2017	35.335	35.520	0.522
24/04/2017	35.602	35.700	0.274
25/04/2017	35.667	36.060	1.090
26/04/2017	35.825	35.400	1.200
27/04/2017	35.522	35.370	0.429
28/04/2017	35.429	35.260	0.479
1/05/2017	35.303	35.270	0.094
2/05/2017	35.161	33.880	3.781
3/05/2017	34.117	33.010	3.353
4/05/2017	33.180	33.690	1.515
5/05/2017	33.771	33.710	0.181
8/05/2017	33.586	33.830	0.722
9/05/2017	33.996	34.170	0.510
10/05/2017	34.276	34.920	1.844
11/05/2017	34.868	34.600	0.774
12/05/2017	34.684	34.680	0.011
15/05/2017	34.792	34.600	0.554
16/05/2017	34.680	33.660	3.029
17/05/2017	33.778	33.660	0.351
18/05/2017	33.573	34.580	2.911
19/05/2017	34.675	35.100	1.212
22/05/2017	35.133	35.010	0.352
23/05/2017	35.064	34.810	0.730
24/05/2017	34.857	34.900	0.124
MAPE			1.039

Fuente: elaboración propia




Figure 6-3. Precio predicho vs precio real – Southern Copper

Fuente: elaboración propia

Barrick Corporation (ABX)

Se realizó el mismo experimento para la empresa Barrick Corporation, la cual es la primera empresa en el mundo en producción de oro y que opera en la bolsa de New York. Más del 75% de su producción proviene de la región de América, donde sus operaciones en Perú se centran en los sectores de Lagunas Norte y Pierina.

Adicionalmente a la producción de oro, Barrick también abarca la producción de cobre y plata, por lo que son estos metales los que fueron considerados a la hora de realizar el entrenamiento y validación.

La Tabla 6-12 muestran los resultados de la evaluación del modelo propuesto para ABX en el periodo de tiempo desde el 12 de Abril del 2017 al 24 de Mayo del 2017 (considerando también información de los 30 días anteriores para calcular las variables técnicas), mientras que la Figura 6-4 muestra los valores de la Tabla 6-13 trazados en el gráfico precio vs fecha.

Tabla 6-12 Precio predicho vs precio real – Barrick Corporation

Fecha	Precio Predicción	Precio Real	Error Porcentual
12/04/2017	19.935	19.830	0.531
13/04/2017	19.710	19.840	0.655
17/04/2017	19.650	19.710	0.304
18/04/2017	19.482	18.910	3.022

19/04/2017	18.816	19.200	2.002
20/04/2017	18.927	19.230	1.576
21/04/2017	18.992	19.040	0.254
24/04/2017	18.865	16.890	11.691
25/04/2017	16.994	16.960	0.198
26/04/2017	16.832	16.710	0.733
27/04/2017	16.692	16.720	0.168
28/04/2017	16.774	16.360	2.533
1/05/2017	16.478	16.410	0.414
2/05/2017	16.466	16.210	1.578
3/05/2017	16.342	16.000	2.137
4/05/2017	16.119	16.150	0.193
5/05/2017	16.301	16.260	0.252
8/05/2017	16.336	16.280	0.341
9/05/2017	16.378	16.390	0.075
10/05/2017	16.542	16.700	0.947
11/05/2017	16.817	16.870	0.313
12/05/2017	16.984	16.900	0.494
15/05/2017	17.018	16.960	0.341
16/05/2017	17.060	17.110	0.289
17/05/2017	17.179	16.510	4.053
18/05/2017	16.679	16.650	0.171
19/05/2017	16.738	16.880	0.840
22/05/2017	16.937	16.420	3.147
23/05/2017	16.604	16.710	0.635
24/05/2017	16.717	16.290	2.624
MAPE			1.417

Fuente: elaboración propia




Figura 6-4. Precio predicho vs precio real – Barrick Corporation

Fuente: elaboración propia

Billiton Limited (BHP)

Billiton es una empresa australiana multinacional dedicada a la minería, metales y petróleo, que tiene una de las mayores producciones de cobre en el mundo, adicionalmente se dedica a la extracción de cobre, plata, oro y zinc. Opera en 25 países y es una de las empresas mineras más importantes del mundo.

Barrick Gold y Billiton Limited fueron seleccionadas debido a su importancia dentro de la industria minera mundial y también debido a su importancia dentro de la bolsa de valores de New York.

La Tabla 6-13 muestra los resultados de la evaluación del modelo propuesto para BHP en el periodo de tiempo desde el 12 de Abril del 2017 al 24 de Mayo del 2017 (considerando también información de los 30 días anteriores para calcular las variables técnicas), mientras que la Figura 6-5 muestra los valores de la Tabla 6-14 trazados en el gráfico precio vs fecha.

Tabla 6-13 *Precio predicho vs precio real - Billiton Limited*

Fecha	Precio Predicción	Precio Real	Error porcentual
12/04/2017	36.278	36.090	0.521
13/04/2017	35.993	36.250	0.708
17/04/2017	36.195	35.570	1.758
18/04/2017	35.516	35.440	0.215

19/04/2017	35.532	35.990	1.273
20/04/2017	36.076	35.760	0.883
21/04/2017	35.839	36.160	0.887
24/04/2017	36.222	36.340	0.325
25/04/2017	36.353	36.050	0.841
26/04/2017	36.078	35.010	3.050
27/04/2017	35.030	35.600	1.600
28/04/2017	35.801	35.840	0.108
1/05/2017	36.058	35.380	1.917
2/05/2017	35.434	34.180	3.668
3/05/2017	34.184	33.820	1.076
4/05/2017	33.875	34.490	1.782
5/05/2017	34.745	34.030	2.101
8/05/2017	34.055	34.400	1.004
9/05/2017	34.440	35.100	1.881
10/05/2017	35.170	35.180	0.027
11/05/2017	35.221	35.200	0.059
12/05/2017	35.217	35.700	1.354
15/05/2017	35.825	36.090	0.735
16/05/2017	36.122	35.420	1.982
17/05/2017	35.332	35.900	1.582
18/05/2017	35.860	36.710	2.316
19/05/2017	36.807	36.890	0.224
22/05/2017	36.854	36.660	0.530
23/05/2017	36.516	36.490	0.072
24/05/2017	36.418	36.210	0.575
MAPE			1.169

Fuente: elaboración propia




Figura 6-5. Precio predicho vs precio real - Billiton Limited

Fuente: elaboración propia

7 Capítulo 7. Conclusiones y trabajos futuros

7.1 Conclusiones

- En este trabajo se desarrolló un Sistema Inteligente basado en un modelo híbrido que ha permitido mejorar la predicción del precio de cierre diario de una acción tomando como casos de estudio a cinco empresas mineras que cotizan en la Bolsa de valores de New York.
- No se han encontrado estudios de predicción del precio en empresas mineras en los últimos 7 años, esto ha conllevado, que la presente tesis se centre en este sector, considerado uno de lo más volátil. Con el fin de comparar los resultados obtenidos se ha elegido el sector más cercano dentro de la literatura (sector petrolero), donde se demostró la efectividad del modelo propuesto, logrando tener un error menor (MAPE: 1.349) al obtenido en la literatura (MAPE: 5.450).
- Los autores en la revisión de la literatura han identificado variables fundamentales y variables técnicas. El modelo planteado en la tesis permitió obtener, luego de una serie de entrevistas a expertos, variables adicionales, las cuales son principalmente: el precio de los metales asociados a las empresas mineras, el precio del dólar y el precio de los índices asociados a la bolsa donde cotizará la acción de EE.UU y Perú.
- En base a los trabajos realizados por los autores, se identificaron las técnicas para la selección de variables más utilizadas, dando como resultado el coeficiente de correlación, el cual estuvo presente en 3 trabajos: Wei et al. (2011); Laboissiere et al. (2015); Wang et al. (2016).
- Con el objetivo de encontrar el valor adecuado para el coeficiente de correlación de Pearson, se comparó un coeficiente utilizado por el autor Wang et al. (2016) (valor coeficiente: 0.32428) con uno propuesto (valor coeficiente: 0.8) donde se concluyó que mientras mayor es el coeficiente de correlación mejores son los resultados, es por ello que el valor elegido para utilizarse en el modelo, fue el coeficiente propuesto.
- En base a la revisión de la literatura se identificaron 48 variables que influían en la predicción del precio, luego de haber hecho un análisis de correlación se logró identificar las variables más influyentes en el precio de cierre por cada caso de estudio, permitiendo disminuir el error de la predicción.
- Se identificaron todas las técnicas de inteligencia artificial que fueron usadas en la revisión de la literatura, las cuales se enfocaban en el problema de predicción del precio

y se observó que la mayoría de trabajos, realizaban comparaciones de una técnica con otra técnica, mas no generaban modelos híbridos que en algunos casos daban mejores resultados.

- De acuerdo a todos los trabajos revisados en la revisión de la literatura se ha obtenido que la técnica de inteligencia artificial que menor error ha tenido en la mayoría de experimentos realizado ha sido MLP, por ello es esta la que se presenta como la técnica utilizada en el modelo híbrido para predicción.
- Las métricas más utilizadas dentro de la literatura fueron MAPE y RMSE, es por eso que fueron seleccionadas para ser evaluadas en el modelo propuesto, tanto para la etapa de entrenamiento, como validación. Es importante mencionar también que, si bien son dos métricas distintas, MAPE es la métrica principal, debido a la mayor presencia en las investigaciones revisadas.
- Si bien esta tesis se enfoca en el sector minero, el sistema planteado también puede ser utilizado en otros sectores, por ello con el fin de demostrar la efectividad del sistema, se hicieron pruebas con las empresas utilizadas por los autores, donde se demostró que, en 9 de los 17 casos de estudio realizados en la literatura, el sistema supera en resultados.
- Se desarrolló un software bajo un modelo híbrido donde se utilizaron tres técnicas de inteligencia artificial: máquinas de soporte vectorial de regresión, función de base radial y redes neuronales artificiales con el fin de combinar las tres técnicas con mejores resultados en la literatura permitiendo formar un modelo híbrido que mejore los resultados de los autores.
- El sistema permite diferenciar dos usuarios para realizar la predicción, ya sea un administrador, el cual tendrá acceso a todo el sistema, como también un usuario operador quien de una forma fácil y clara podrá utilizar el sistema y realizar predicciones.
- El modelo propuesto no solo se limita a clasificar el precio futuro como alza o baja en un determinado día como lo hacen algunos autores, en lugar de eso permite saber en cuánto el precio se ha incrementado o ha disminuido, para ello se muestra el precio final de la predicción, permitiendo comparar el precio actual y precio de la predicción.

7.2 Trabajos futuros

- Complementar el trabajo realizado desarrollando un sistema inteligente que determine, en base al precio predicho de nuestro sistema, cuántas acciones comprar o vender en un momento dado.
- Aplicar el modelo propuesto en otros sectores, tales como el tecnológico, industrial, etc.

8 Referencias

- Abu-Mostafa, Y., & Atiya, A. (1996). Introduction to financial forecasting. *Applied Intelligence*. 6 (3), 205–213.
- Academic. (s.f.). *Perceptrón multicapa*. Obtenido de Interpretaciones: <http://www.esacademic.com/dic.nsf/eswiki/922098>
- AEMARK . (2016). *XXVIII Congreso de Marketing*. . León: ESIC Editorial.
- Bebarta, D., & Rout, A. (2016). A Typical Framework for Forecasting and Trading Time Series Data Using Functional Link Artificial Neural Network. *International Journal of Engineering and Technology*. 8 (2), 1238-1244.
- Bebarta, D., Biswal, B., & Dash, P. (2015). Polynomial based functional link artificial recurrent neural network adaptive system for predicting Indian stocks. *International Journal of Computational Intelligence Systems*. 8 (6), 1004-1016.
- Bolsa de Valores de Lima. (s.f.). *Inicio*. Obtenido de <https://www.bvl.com.pe/>
- Boyacioglu, M., & Avci, D. (2010). An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the prediction of stock market return: The case of the Istanbul Stock Exchange. *Expert Systems with Applications*. 37 (12), 7908-7912.
- Carmona, E. (2014). *Tutorial sobre Máquinas de Vectores Soporte (SVM)*. Madrid: UNED.
- Chang, P., Liu, C., Lin, J., Fan, C., & Ng, C. (2009). A neural network with a case based dynamic window for stock trading prediction. . *Expert Systems with Applications*. 36 (3), 6889-6898.
- Chang, T. (2011). A comparative study of artificial neural networks, and decision trees for digital game content stocks price prediction. *Expert Systems with Applications*. 38 (12), 14846-14851.
- Cheng, J., Chen, H., & Lin, Y. (2010). A hybrid forecast marketing timing model based on probabilistic neural network, rough set and C4. 5. . *Expert Systems with Applications*. 37 (3), 1814-1820.
- Dai, W., Wuc, J., & Lu, C. (2012). Combining nonlinear independent component analysis and neural network for the prediction of Asian stock market indexes. *Expert Systems with Applications*. 39 (4), 4444-4452.

- de Oliveira, F., Nobre, C., & Zarate, L. (2013). Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index-Case study of PETR4, Petrobras, Brazil. . *Expert Systems with Applications*. 40 (18), 7596-7606.
- Dutta, G., Jha, P., Laha, A., & Mohan, N. (2006). Artificial neural network models for forecasting stock price index in the Bombay stock exchange. . *Journal of Emerging Market Finance*. 5 (3), 283-295.
- Eckert, K., & Suénaga, R. (2013). *Aplicación de técnicas de Minería de Datos al análisis de situación y comportamiento académico de alumnos de la UGD*. Posadas: Universidad Gastón Dachary.
- Egeli, B., Ozturan, M., & Badur, B. (2003). *Stock market prediction using artificial neural networks*. . Honolulu: Proceedings of the 3rd Hawaii international conference on business.
- Fayyad, U., Shapiro, G., Smyth, P., & Uhturudsamy, R. (1996). *Advances in Knowledge Discovery & Data Mining, 1era Edición*. Rhode Island: Editorial MIT Press.
- Flórez, R., & Fernández, J. (2008). *Las Redes Neuronales Artificiales*. La Coruña: Netbiblo, S.L.
- Gocken, M., Ozcalici, M., Boru, A., & Dosdogru, A. (2016). Integrating metaheuristics and artificial neural networks for improved stock price prediction. *Expert Systems with Applications*. 44, 320-331.
- Guo, Z., Wang, H., Yang, J., & Miller, D. (2015). A Stock Market Forecasting Model Combining Two-Directional Two-Dimensional Principal Component Analysis and Radial Basis Function Neural Network. *Plos One*. 10 (4), 1-19.
- Guresen, E., Kayakutlu, G., & Daim, T. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*. 38 (8), 10389-10397.
- Hadavandi, E., Shavandi, H., & Ghanbari, A. (2010). Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting. *Knowledge-Based Systems*. 23 (8), 800-808.
- Hassan, M., Nath, B., & Kirley, M. (2007). A fusion model of HMM, ANN and GA for stock market forecasting. . *Expert Systems with Applications*. 33 (1), 171-180.

- Hassan, R., & Nath, B. (2005). *Stock market forecasting using Hidden Markov Model: A new approach*. Washington, D.C.: 5th International Conference on Intelligent Systems Design and Application.
- Hellström, T., & Holmström, K. (1998). *Predicting the stock market*. Västerås: Mälardalen University.
- Hsu, C. (2011). A hybrid procedure for stock price prediction by integrating self-organizing map and genetic programming. *Expert Systems with Applications*. 38 (11), 14026-14036.
- Huang, C., & Tsai, C. (2009). A hybrid SOFM-SVR with a filter-based feature selection for stock market forecasting. . *Expert Systems with Applications*. 36 (2), 1529-1539.
- Joao, R., Guidoni, T., Bertini, J., Nicoletti, M., & Artero, A. (2014). *Stock closing price forecasting using ensembles of constructive neural networks*. Sao Paulo: Brazilian Conference on Intelligent Systems (BRACIS).
- Kara, Y., Boyacioglu, M., & Baykan, Ö. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*. 38 (5), 5311-5319.
- Laboissiere, L., Fernandes, R., & Lage, G. (2015). Maximum-and-minimum-stock-price-forecasting-of-Brazilian-power-distribution-companies-based-on-artificial-neural-networks. *Applied Soft Computing*. 35, 66-74.
- Lu, C., Lee, T., & Chiu, C. (2009). Financial time series forecasting using independent component analysis and support vector regression. . *Decision Support Systems*. 47 (2), 115-125.
- Lu, C.-J. (2010). Integrating independent component analysis-based denoising scheme with neural network for stock price prediction. *Expert Systems with Applications*. 37 (10), 7056-7064.
- Marín, J. (s.f.). *Introducción a las redes neuronales aplicadas*. Obtenido de Personal : <http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema3dm.pdf>
- Mitra, A., & Wang, L. (2015). *Improving Artificial Neural Network based Stock Forecasting using Fourier De-Noising and Hodrick-Prescott Filter*. Singapore: 10th International Conference on Information, Communications and Signal Processing (ICICS).

- Ouahilal, M., Mohajir, M., Chahhou, M., & Eddine, B. (2016). *Optimizing Stock Market Price Prediction using a Hybrid Approach Based on HP Filter and Support Vector Regression*. Tánger: 4th IEEE International Colloquium on Information Science and Technology (CiSt).
- Sarzuri, V. (2014). Algoritmo de Clasificación de Huellas Dactilares Basado en Redes Neuronales Función Base Radial. *Revista PGI*. 21 (1) , 102-108.
- Shafique U. & Qaiser H. (2014). A Comparative Study of Data Mining Process Models (KDD, CRISP-DM and SEMMA). *Innovative Space of Scientific Research Journals*. 12 (14), 217-222
- Tan, T., Quek, C., & Ng, G. (2007). Biological Brain-Inspired Genetic Complementary Learning for Stock Market and Bank Failure Prediction. *Computational Intelligence*. 23 (2), 236-261.
- Ticknor, J. (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications*. 40 (14), 5501-5506.
- Wang, J., Hou, R., Wang, C., & Shen, L. (2016). Improved v-Support Vector Regression Model Based on Variable Selection and Brain Storm Optimization for Stock Price Forecasting. *Applied Soft Computing*. 49, 164-178.
- WebMining Consultores. (2011). *KDD: Proceso de Extracción de conocimiento*. Obtenido de Blog: <http://www.webmining.cl/2011/01/proceso-de-extraccion-de-conocimiento/>
- Wei, L., Chen, T., & Ho, T. (2011). A hybrid model based on adaptive-network-based fuzzy inference system to forecast Taiwan stock market. *Expert Systems with Applications*. 38 (11), 13625-13631.
- Wikipedia. (s.f.). *Máquinas de vectores de soporte*. Obtenido de https://es.wikipedia.org/wiki/M%C3%A1quinas_de_vectores_de_soporte
- Wikipedia. (s.f.b). *Coeficiente de correlación de Pearson*. Obtenido de https://es.wikipedia.org/wiki/Coeficiente_de_correlaci%C3%B3n_de_Pearson
- Yudong, Z., & Lenan, W. (2009). Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network. *Expert Systems with Applications*. 36 (5), 8849-8854.

Zhu, X., Wang, H., Xu, L., & Li, H. (2008). Predicting stock index increments by neural networks: The role of trading volume under different horizons. *Expert Systems with Applications*. 34 (4), 3043-3054.

9 Anexos

9.1 Anexo 1: Fórmulas de las variables fundamentales y técnicas

Variables fundamentales

- Precio apertura: PO
- Precio cierre: PC
- Precio bajo: PB
- Precio alto: PA
- Volumen: V
- Precio de cierre del día anterior:

$$PCA_i = PC_{i-1}$$

- Precio alto del día anterior:

$$PAA_i = PA_{i-1}$$

- Precio bajo del día anterior:

$$PBA_i = PB_{i-1}$$

- Precio de apertura del día anterior:

$$POA_i = PO_{i-1}$$

Variables técnicas

- RSI: Indicador de fuerza relativa

$$RSI = 100 - \frac{100}{1 + (\sum_{i=0}^{n-1} \frac{Up_{t-i}}{n}) + (\sum_{i=0}^{n-1} \frac{Dw_{t-i}}{n})}$$

- M: Momentum

$$M_{10} = PC_i - PC_{i-10}$$

- I_K: Índice K

PMB_{14i} = Precio más bajo en un periodo de 14 días.

PMA_{14i} = Precio más alto en un periodo de 14 días.

$$I_K = \frac{PC - PMB_{14i}}{PMA_{14i} - PMB_{14i}} \times 100\%$$

- I_D: Índice D

$Prom_9$ = Promedio de nueve días

$$I_D = \frac{\sum_{i=0}^9 I_K_i \%}{Prom_9}$$

- **PM: Promedio móvil**

$$PM_{10} = \frac{\sum_{i=1}^{10} PC_i}{10}$$

- **William (W)**

PMB_{9i} = Precio más bajo en un periodo de 9 días.

PMA_{9i} = Precio más alto en un periodo de 9 días.

$$W = \frac{PA_{9i} - PC}{PA_{9i} - PB_{9i}} \times 100\%$$

- **OBV: Índice del balance de volúmenes**

$$OBV_{primer} = 0$$

$$OBV_i = OBV_{i-1} + Volumen_R$$

Dónde:

- $Volumen_R = Volumen(PC > PC_{i-1})$

- $Volumen_R = 0(PC = PC_{i-1})$

$$Volumen_R = -Volumen(PC < PC_{i-1})$$

- **Banda media de Bollinger**

$$Bollinger_{media} = PM_{20}$$

- **Banda alta de Bollinger**

$$Bollinger_{alta} = PM_{20} + \delta_{20}$$

- **Precio medio**

$$P_{medio} = \frac{PA_i + PC_i + PB_i}{3}$$

- **Monto:**

$$P_{medio} * Volumen$$

- **BIAS_20**

PM_{20} = Promedio móvil de un periodo de 20 días.

$$BIAS_{20i} = \frac{PC_i - PM_{20}}{PM_{20}}$$

- **PVC**

$$PVC = \frac{\sum_{i=1}^n (\Delta PC_i \times \Delta v_i)}{\sum_{i=1}^n (|\Delta PC_i \times \Delta v_i|)}$$

- **MAVI**

PMV_{20} = Promedio móvil del volumen de un periodo de 20 días.

PMV_{20} = Promedio móvil del volumen de un periodo de 20 días.

$$MAVI = \frac{PC_i - PM_{20}}{PM_{20}}$$

- **MACD** Movimiento promedio de convergencia/divergencia:

Definimos el índice de la demanda:

$$DI_i = \frac{(PA_i + PB_i + 2 * PC_i)}{4}$$

Calculamos el movimiento promedio exponencial de 12 y 26 días:

$$EMA_{12i} = \frac{11}{13} * EMA_{12i-1} + \frac{2}{13} * DI_i$$

$$EMA_{26i} = \frac{25}{27} * EMA_{26i-1} + \frac{2}{27} * DI_i$$

Calculamos la diferencia entre los promedios exponenciales:

$$DIF_i = EMA_{12i} - EMA_{26i}$$

Calculamos el movimiento promedio de convergencia y divergencia:

$$MACD_i = \frac{8}{10} * MACD_{i-1} + \frac{2}{10} * DIF_i$$

- **AR**: Indicador del momentum de compra y venta para un periodo de 26 días.

$$AR_{26_i} = \frac{\sum_{j=i-25}^i (PA_j - PO_j)}{\sum_{j=i-25}^i (PO_j - PB_j)}$$

- **BR:** Indicador de complacencia de compra y venta para un periodo de 26 días.

$$BR_{26_i} = \frac{\sum_{j=i-25}^i (PA_j - PC_{j-1})}{\sum_{j=i-25}^i (PC_{j-1} - PB_j)}$$

- **ROC**

PC_{i-10} = Precio de cierre de 10 días anteriores.

PC_i = Precio de cierre del día actual

$$ROC_{10_i} = \frac{PC_i - PC_{i-10}}{PC_{i-10}} * 100$$

- **DI14positivo (+DI₁₄):**

Es el indicador direccional positivo que es definido como el cociente del movimiento direccional y el rango verdadero en un periodo de 14 días.

$+DM_{14_i}$ = Movimiento direccional positivo de un periodo de 14 días.

TR_{14_i} = Rango verdadero de un periodo de 14 días.

$$+DI_{14_i} = \frac{+DM_{14_i}}{TR_{14_i}}$$

Donde, el numerador, movimiento direccional ($+DM_{14_i}$), es calculado de la siguiente manera:

$$+DM_{14_i} = \frac{13}{14} x (+DM_{14_{i-1}}) + \frac{1}{14} x (+TDM_i)$$

Donde la variable mínimo movimiento direccional negativo ($+TDM$) puede ser calculada como:

$$+TDM_i = \begin{cases} +DM_i, & \text{si } (+DM_i > -DM_i) \text{ y } (+DM_i > 0) \\ 0, & \text{caso contrario.} \end{cases}$$

Y el movimiento direccional positivo ($+DM_i$) como:

$$+DM_i = HP_i - HP_{i-1}$$

El denominador, rango verdadero (TR), se define como:

$$TR_i = \text{Max}\{PA_i - PB_i, |PA_i - PC_{i-1}|, |PB_i - PC_{i-1}|\}$$

Pero como se hace uso de un periodo de 14 días, el rango verdadero (TR) será definido como:

$$TR_{14_i} = \frac{13}{14}x(TR_{14_{i-1}}) + \frac{1}{14}x(TR_i)$$

- **Indicador direccional negativo ($-DI_{14_i}$):**

Es el indicador direccional negativo que es definido como el cociente del movimiento direccional y el rango verdadero en un periodo de 14 días.

$-DM_{14_i}$ = Movimiento direccional positivo de un periodo de 14 días.

TR_{14_i} = Rango verdadero de un periodo de 14 días.

$$-DI_{14_i} = \frac{-DM_{14_i}}{TR_{14_i}}$$

Donde, el numerador, movimiento direccional ($-DM_{14_i}$), es calculado de la siguiente manera:

$$-DM_{14_i} = \frac{13}{14}x(-DM_{14_{i-1}}) + \frac{1}{14}x(-TDM_i)$$

Donde la variable mínimo movimiento direccional negativo ($-TDM$) puede ser calculada como:

$$-TDM_i = \begin{cases} -DM_i, & \text{si } (+DM_i < -DM_i) \text{ y } (-DM_i > 0) \\ 0, & \text{caso contrario.} \end{cases}$$

Y el movimiento direccional positivo ($-DM_i$) como:

$$-DM_i = LP_{i-1} - LP_i$$

El denominador, rango verdadero (TR), se define como:

$$TR_i = \text{Max}\{PA_i - PB_i, |PA_i - PC_{i-1}|, |PB_i - PC_{i-1}|\}$$

Pero como se hace uso de un periodo de 14 días, el rango verdadero (TR) será definido como:

$$TR_{14_i} = \frac{13}{14}x(TR_{14_{i-1}}) + \frac{1}{14}x(TR_i)$$

- **DIF: Diferencia**

$$DIF = PC_i - PC_{i-1}$$

- **PSY: Línea psicológica**

$$PSY_{13_i} = \frac{TDU_{13_i}}{13}x100\%$$

Donde TDU_{13_i} es el número total de días en los que el precio aumentó con respecto al día anterior.

- **CCI: Índice del canal de mercaderías**

Definimos el precio típico:

$$TP_i = \frac{PA_i + PB_i + PC_i}{3}$$

Calculamos el promedio simple de los 24 días:

$$SMATP_{24_i} = \frac{\sum_{j=i-23}^i TP_j}{24}$$

Calculamos la desviación media:

$$MD_{24_i} = \frac{\sum_{j=i-23}^i |TP_j - SMATP_{24_i}|}{24}$$

Calculamos el índice del canal de mercaderías:

$$CCI_{24_i} = \frac{TP_i - SMATP_{24_i}}{0.015 * MD_{24_i}}$$

9.2 Anexo 2: Formulario y resultado de encuestas

Formulario:

Encuesta

Soy egresado de la UNMSM de la carrera de Ingeniería de Sistemas e Informática, estoy realizando una encuesta para saber cuáles son los factores más influyentes que afectan el análisis del precio futuro de las acciones en la Bolsa de Valores. Esto me ayudará a realizar un mejor trabajo de investigación. La encuesta solo tomara 5 minutos aproximadamente.

***Obligatorio**

1. Nombre y Apellido

2. Usted Invierte en:

Marca solo un óvalo.

☐ Bolsa

☐ Forex

☐ Ambas

☐ Otro:

3. Años de experiencia invirtiendo en bolsa *

4. ¿Ha invertido usted en acciones mineras?

5. ¿Que factores consideraría usted al invertir en una acción minera a corto plazo en la bolsa de New York? ¿Porque? *

6. ¿Consideraría usted el precio de los metales que comercializa la empresa en la pregunta anterior? ¿Por qué?

7. ¿Consideraría usted el precio del dólar en la pregunta 4? ¿Por qué?

Con la tecnología de
 Google Forms

Figura 9-1. Formulario de preguntas

Fuente: elaboración propia

Resultados:

Nombre y Apellido

6 respuestas

Francisco Lodeiro
Roberto Guadalupe.
Kevin Horna
Maria Emilia Gimenez
Erick Gálvez
Marco Antonio Puerta

Usted invierte en:

6 respuestas




Figura 9-2. Resultado encuesta – primera parte

Fuente: elaboración propia

Años de experiencia invirtiendo en bolsa

6 respuestas

10
15
6
8
9
22

¿Ha invertido usted en acciones mineras?

6 respuestas




Figura 9-3. Resultado encuesta – segunda parte

Fuente: elaboración propia

¿Que factores consideraria usted al invertir en una acción minera a corto plazo en la bolsa de New York? ¿Porque?

6 respuestas

No invierto nunca a corto plazo.

Tendencia de sus precios. Análisis Técnico. "Una mirada al gráfico vale más que mil predicciones".

maximos historicos, porque todos los que estan en compra estan ganando

El dolar, la direccion de las bolsas y el precio de los minerales en cuestión.

Factor externos como el consumo o crecimientos de China e India

El precio del metal con el que trabaja la empresa, oro, plata, zinc, estaño.

¿Consideraría usted el precio de los metales que comercializa la empresa en la pregunta anterior? ¿Por qué?

6 respuestas

Sí, ya que es un factor determinante a la hora de valorar la compañía.

NO. Al invertir/especular en el valor anterior la decisión de compra realizada se da porque se ve la tendencia de los precios al alza. El precio de los metales no es la única variable para que una acción minera suba; existen variables endógenas (propias de la empresa) y exógenas (contexto macroeconómico) que condicionan los precios en una dirección(alcista o bajista).

no

Si

Si, el valor del metal va repercutir en los estados de las empresas también

Si, influye en el precio de la acción.

¿Consideraría usted el precio del dólar en la pregunta 4? ¿Por qué?

6 respuestas

Si (2)

Sí, ya que las materias primas cotizan en dólares en los mercados internacionales.

NO. El precio del dólar es normalmente inverso a la cotización de los metales. Los inversionistas/especuladores, normalmente, o invierten en dólares o en metales.

no

No, no encuentro relación

Figura 9-4. Resultado encuesta – tercera parte

Fuente: elaboración propia

9.3 Anexo 3: Resultado de pruebas

9.3.1 Buenaventura (BVN)

Resultados para la técnica RBFN:

Parámetros	Entrenamiento		Validación	
N funciones	MAPE	RMSE	MAPE	RMSE
2	3.071	36.863	1.833	28.436
3	2.910	35.123	1.733	27.859
4	2.889	34.834	1.741	28.080
5	2.881	34.746	1.731	27.968
6	2.797	33.709	1.768	28.104
7	2.796	33.639	1.762	28.042
8	2.732	32.794	2.074	32.925
9	2.721	32.436	1.872	29.415
10	2.639	31.270	2.066	33.411
12	2.573	30.620	2.213	34.668
14	2.558	30.391	3.551	56.613
16	2.497	29.621	2.568	42.333
18	2.498	29.314	2.037	33.099
20	2.469	28.640	2.353	40.545
25	2.313	27.055	3.207	50.843
30	2.132	25.204	2.829	45.747
35	2.110	23.947	3.856	62.342
40	2.031	23.127	2.935	49.835
45	1.915	22.763	3.001	47.801
50	1.539	18.635	3.895	61.597

Resultados para la técnica SVR:

Parámetros		Entrenamiento		Validación	
C	Grado	MAPE	RMSE	MAPE	RMSE
2^{-1}	1	2.870	35.446	1.729	28.185
2^1	1	2.847	35.074	1.719	28.106
2^3	1	2.842	34.981	1.731	28.222
2^5	1	2.838	35.025	1.748	28.417
2^7	1	2.842	35.005	1.737	28.326
275	1	2.839	35.019	1.739	28.311
2^9	1	2.842	35.043	1.745	28.433
2^{-1}	2	8.543	82.920	1.973	31.304
2^1	2	8.436	81.801	1.739	28.311
2^3	2	8.086	78.677	3.147	49.629
2^5	2	7.030	69.572	3.027	48.008

2⁷	2	4.335	47.099	2.270	36.017
275	2	3.314	38.899	1.973	31.304
2⁹	2	2.975	36.432	1.817	29.903
1	1	2.857	35.221	1.736	28.290
3	1	2.844	35.042	1.727	28.182
4	1	2.844	35.025	1.729	28.237
5	1	2.841	35.024	1.733	28.244
6	1	2.842	35.007	1.731	28.242
7	1	2.841	34.982	1.732	28.240
8	1	2.842	34.981	1.731	28.222
9	1	2.842	35.029	1.734	28.251
10	1	2.843	35.000	1.734	28.288
20	1	2.840	34.998	1.735	28.274
30	1	2.842	34.979	1.736	28.271
40	1	2.840	34.976	1.729	28.242
50	1	2.839	35.001	1.739	28.303
60	1	2.839	35.008	1.740	28.323
70	1	2.840	35.003	1.740	28.301
80	1	2.839	34.999	1.736	28.279
90	1	2.840	35.007	1.741	28.309
100	1	2.841	35.007	1.736	28.318

Resultados para la técnica RNA:

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	2.953	35.681	1.780	28.046
0.2	1000	0.004	6	2.950	35.768	1.786	28.028
0.2	1000	0.004	10	2.930	35.701	1.778	27.999
0.2	1000	0.004	13	2.922	35.764	1.771	28.001
0.2	1000	0.004	90	2.946	36.654	1.714	28.317
0.2	1000	0.004	100	2.962	36.833	1.720	28.447
0.2	1000	0.04	5	2.881	34.990	1.680	27.560
0.2	1000	0.04	6	2.873	34.970	1.678	27.542
0.2	1000	0.04	10	2.859	35.011	1.679	27.536
0.2	1000	0.04	13	2.865	35.202	1.694	27.687
0.2	1000	0.04	90	2.952	36.079	1.720	27.797
0.2	1000	0.04	100	2.898	35.438	1.664	27.177
0.2	1000	0.1	5	2.872	35.393	1.787	28.804
0.2	1000	0.1	6	2.875	35.414	1.774	28.643
0.2	1000	0.1	10	2.899	35.636	1.780	28.737
0.2	1000	0.1	13	2.912	35.952	1.796	28.885
0.2	1000	0.1	90	3.299	39.733	2.078	32.442

0.2	1000	0.1	100	3.327	39.938	2.088	32.605
0.2	10000	0.004	5	2.884	34.769	1.696	27.754
0.2	10000	0.004	6	2.881	34.775	1.698	27.776
0.2	10000	0.004	10	2.876	34.758	1.696	27.768
0.2	10000	0.004	13	2.873	34.768	1.695	27.778
0.2	10000	0.004	90	2.867	34.846	1.672	27.509
0.2	10000	0.004	100	2.870	34.884	1.673	27.485
0.2	10000	0.04	5	2.815	34.081	1.715	27.911
0.2	10000	0.04	6	2.826	34.081	1.723	27.962
0.2	10000	0.04	10	2.821	34.161	1.717	27.848
0.2	10000	0.04	13	2.821	34.249	1.722	27.867
0.2	10000	0.04	90	2.843	34.923	1.734	28.036
0.2	10000	0.04	100	2.856	35.120	1.744	28.169
0.2	10000	0.1	5	2.792	33.882	1.742	27.788
0.2	10000	0.1	6	2.785	33.710	1.749	27.666
0.2	10000	0.1	10	2.779	33.527	1.776	28.784
0.2	10000	0.1	13	2.783	33.521	1.780	28.902
0.2	10000	0.1	90	2.794	33.668	1.811	29.429
0.2	10000	0.1	100	2.800	34.013	1.780	28.628
0.4	1000	0.004	5	2.933	35.445	1.759	28.011
0.4	1000	0.004	6	2.928	35.497	1.763	27.987
0.4	1000	0.004	10	2.911	35.446	1.757	27.959
0.4	1000	0.004	13	2.902	35.491	1.750	27.945
0.4	1000	0.004	90	2.966	36.736	1.736	28.476
0.4	1000	0.004	100	2.993	37.012	1.752	28.671
0.4	1000	0.04	5	2.872	35.108	1.713	27.894
0.4	1000	0.04	6	2.867	35.098	1.711	27.859
0.4	1000	0.04	10	2.865	35.204	1.713	27.908
0.4	1000	0.04	13	2.878	35.477	1.740	28.191
0.4	1000	0.04	90	3.789	43.676	2.420	36.601
0.4	1000	0.04	100	3.751	43.395	2.416	36.555
0.4	1000	0.1	5	2.900	35.895	1.860	29.790
0.4	1000	0.1	6	2.898	35.907	1.833	29.429
0.4	1000	0.1	10	2.924	36.148	1.842	29.548
0.4	1000	0.1	13	2.948	36.516	1.873	29.924
0.4	1000	0.1	90	3.618	42.736	2.353	35.961
0.4	1000	0.1	100	3.689	43.422	2.405	36.608
0.4	10000	0.004	5	2.882	34.731	1.694	27.720
0.4	10000	0.004	6	2.879	34.738	1.695	27.748
0.4	10000	0.004	10	2.872	34.721	1.693	27.741
0.4	10000	0.004	13	2.868	34.731	1.693	27.744
0.4	10000	0.004	90	2.871	34.903	1.679	27.508
0.4	10000	0.004	100	2.877	34.962	1.679	27.492
0.4	10000	0.04	5	2.806	33.925	1.716	27.923

0.4	10000	0.04	6	2.817	34.008	1.714	27.603
0.4	10000	0.04	10	2.811	34.009	1.715	27.786
0.4	10000	0.04	13	2.805	34.105	1.725	27.857
0.4	10000	0.04	90	2.806	34.425	1.743	28.048
0.4	10000	0.04	100	2.815	34.578	1.753	28.192
0.4	10000	0.1	5	2.788	33.908	1.765	28.044
0.4	10000	0.1	6	2.785	33.782	1.763	27.947
0.4	10000	0.1	10	2.764	33.353	1.793	28.917
0.4	10000	0.1	13	2.768	33.387	1.796	29.068
0.4	10000	0.1	90	2.781	33.542	1.818	29.440
0.4	10000	0.1	100	2.788	33.682	1.812	29.330
0.4	1000	0.02	5	2.900	34.938	1.663	27.439

Resultados para el modelo híbrido (RNA):

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	2.954	35.312	1.766	28.106
0.2	1000	0.004	6	2.947	35.281	1.757	27.974
0.2	1000	0.004	10	2.922	35.159	1.749	27.830
0.2	1000	0.004	13	2.909	35.116	1.744	27.883
0.2	1000	0.004	90	2.873	35.612	1.703	27.933
0.2	1000	0.004	100	2.877	35.680	1.704	27.949
0.2	1000	0.04	5	2.894	34.958	1.713	27.876
0.2	1000	0.04	6	2.886	34.942	1.709	27.820
0.2	1000	0.04	10	2.869	35.005	1.712	27.844
0.2	1000	0.04	13	2.864	35.144	1.721	27.950
0.2	1000	0.04	90	2.907	35.660	1.726	27.864
0.2	1000	0.04	100	2.865	35.099	1.666	27.255
0.2	1000	0.1	5	2.854	35.205	1.811	29.132
0.2	1000	0.1	6	2.854	35.202	1.807	29.073
0.2	1000	0.1	10	2.873	35.505	1.826	29.280
0.2	1000	0.1	13	2.890	35.748	1.848	29.498
0.2	1000	0.1	90	3.175	38.513	2.082	32.423
0.2	1000	0.1	100	3.217	38.732	2.078	32.418
0.2	10000	0.004	5	2.886	34.573	1.716	27.899
0.2	10000	0.004	6	2.886	34.580	1.715	27.894
0.2	10000	0.004	10	2.881	34.570	1.715	27.909
0.2	10000	0.004	13	2.877	34.574	1.712	27.896
0.2	10000	0.004	90	2.846	34.748	1.713	27.856
0.2	10000	0.004	100	2.847	34.810	1.714	27.856
0.2	10000	0.04	5	2.807	33.859	1.743	28.134
0.2	10000	0.04	6	2.825	34.035	1.748	28.156

0.2	10000	0.04	10	2.839	34.248	1.750	28.255
0.2	10000	0.04	13	2.840	34.312	1.746	28.166
0.2	10000	0.04	90	2.856	34.996	1.758	28.356
0.2	10000	0.04	100	2.872	35.203	1.760	28.383
0.2	10000	0.1	5	2.786	33.786	1.750	27.773
0.2	10000	0.1	6	2.786	33.801	1.747	27.734
0.2	10000	0.1	10	2.788	33.813	1.747	27.842
0.2	10000	0.1	13	2.778	33.468	1.775	28.739
0.2	10000	0.1	90	2.800	34.013	1.786	28.764
0.2	10000	0.1	100	2.786	34.006	1.783	28.809
0.4	1000	0.004	5	2.939	35.164	1.752	28.071
0.4	1000	0.004	6	2.933	35.147	1.744	27.957
0.4	1000	0.004	10	2.909	35.035	1.737	27.845
0.4	1000	0.004	13	2.899	35.009	1.733	27.894
0.4	1000	0.004	90	2.893	35.808	1.722	28.140
0.4	1000	0.004	100	2.857	34.962	1.723	27.939
0.4	1000	0.04	5	2.888	35.101	1.745	28.260
0.4	1000	0.04	6	2.880	35.095	1.741	28.218
0.4	1000	0.04	10	2.872	35.246	1.752	28.348
0.4	1000	0.04	13	2.875	35.456	1.771	28.568
0.4	1000	0.04	90	3.727	43.165	2.452	37.056
0.4	1000	0.04	100	3.677	42.744	2.428	36.753
0.4	1000	0.1	5	2.879	35.646	1.872	29.916
0.4	1000	0.1	6	2.890	35.757	1.879	30.014
0.4	1000	0.1	10	2.899	35.935	1.893	30.165
0.4	1000	0.1	13	2.905	36.025	1.911	30.347
0.4	1000	0.1	90	3.520	41.787	2.373	36.145
0.4	1000	0.1	100	3.610	42.659	2.425	36.839
0.4	10000	0.004	5	2.885	34.537	1.720	27.911
0.4	10000	0.004	6	2.884	34.540	1.719	27.906
0.4	10000	0.004	10	2.878	34.536	1.719	27.924
0.4	10000	0.004	13	2.874	34.540	1.717	27.911
0.4	10000	0.004	90	2.850	34.851	1.721	27.903
0.4	10000	0.004	100	2.857	34.962	1.723	27.939
0.4	10000	0.04	5	2.800	33.607	1.748	28.305
0.4	10000	0.04	6	2.807	33.712	1.750	28.244
0.4	10000	0.04	10	2.827	34.095	1.772	28.480
0.4	10000	0.04	13	2.824	34.090	1.750	28.204
0.4	10000	0.04	90	2.826	34.541	1.778	28.687
0.4	10000	0.04	100	2.835	34.722	1.779	28.669
0.4	10000	0.1	5	2.784	33.855	1.769	28.100
0.4	10000	0.1	6	2.786	33.853	1.769	28.081
0.4	10000	0.1	10	2.781	33.628	1.810	29.088
0.4	10000	0.1	13	2.767	33.305	1.796	28.969

0.4	10000	0.1	90	2.778	33.418	1.721	28.106
0.4	10000	0.1	100	2.782	33.431	1.746	28.346

9.3.2 Barrick Gold Corporation (ABX)

Resultados para la técnica RBFN:

Parámetros	Entrenamiento		Validación	
N funciones	MAPE	RMSE	MAPE	RMSE
2	2.589	46.030	1.717	45.917
3	2.360	42.550	1.638	45.007
4	2.297	40.932	1.627	43.839
5	2.299	40.158	2.039	49.006
6	2.270	38.679	2.472	55.180
7	2.250	38.228	2.223	51.718
8	2.213	37.861	3.380	76.758
9	2.189	37.017	1.990	47.627
10	2.148	36.831	2.988	68.368
12	2.117	35.686	3.295	75.066
14	2.050	34.594	2.537	61.409
16	2.009	33.653	3.258	84.791
18	1.921	32.149	2.989	79.652
20	1.913	32.354	3.017	69.193
25	1.814	29.979	2.345	55.782
30	1.719	27.876	2.914	73.119
35	1.618	25.975	2.735	70.635
40	1.583	25.061	2.372	57.549
45	1.482	23.551	2.670	63.981
50	1.465	23.123	2.527	59.573

Resultados para la técnica SVR:

Parámetros		Entrenamiento		Validación	
C	Grado	MAPE	RMSE	MAPE	RMSE
2^{-1}	1	2.391	43.358	1.568	43.178
2^1	1	2.374	43.071	1.573	43.350
2^3	1	2.373	42.933	1.574	43.539
2^5	1	2.373	42.884	1.581	43.504
2^7	1	2.374	42.904	1.585	43.574
275	1	2.372	42.876	1.587	43.558
2^9	1	2.373	42.924	1.590	43.695

2⁻¹	2	7.306	101.021	3.060	69.853
2¹	2	6.582	95.317	3.767	82.107
2³	2	6.155	92.649	4.572	96.223
2⁵	2	5.846	89.039	5.474	113.566
2⁷	2	5.568	87.694	5.831	122.872
275	2	5.502	87.346	5.714	121.896
2⁹	2	5.412	87.090	5.827	124.599
1	1	2.381	43.163	1.575	43.173
2	1	2.374	43.071	1.573	43.350
3	1	2.376	42.970	1.579	43.481
4	1	2.374	42.974	1.588	43.529
5	1	2.374	42.928	1.577	43.384
6	1	2.372	42.917	1.570	43.457
7	1	2.373	42.931	1.580	43.589
8	1	2.373	42.933	1.574	43.539
9	1	2.372	42.986	1.576	43.310
10	1	2.373	42.923	1.572	43.461
20	1	2.372	42.874	1.571	43.558
30	1	2.373	42.883	1.572	43.580
40	1	2.372	42.886	1.586	43.612
50	1	2.371	42.957	1.575	43.279
60	1	2.373	42.930	1.580	43.496
70	1	2.373	42.876	1.581	43.792
80	1	2.373	42.873	1.564	43.409
90	1	2.371	42.926	1.575	43.476
100	1	2.371	42.861	1.577	43.636

Resultados para la técnica RNA:

Parámetros				Entrenamiento		Validación	
Momentum	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	2.473	43.870	1.550	43.543
0.2	1000	0.004	6	2.471	43.846	1.551	43.487
0.2	1000	0.004	10	2.463	43.864	1.547	43.229
0.2	1000	0.004	13	2.465	43.929	1.562	43.468
0.2	1000	0.004	90	2.487	44.615	1.558	42.891
0.2	1000	0.004	100	2.486	44.613	1.547	42.678
0.2	1000	0.04	5	2.510	43.747	1.556	43.655
0.2	1000	0.04	6	2.515	43.805	1.543	43.512
0.2	1000	0.04	10	2.502	43.747	1.523	43.074
0.2	1000	0.04	13	2.493	43.696	1.525	42.974
0.2	1000	0.04	90	2.467	43.923	1.837	48.178
0.2	1000	0.04	100	2.505	44.491	1.928	49.485

0.2	1000	0.1	5	2.481	43.360	1.622	43.873
0.2	1000	0.1	6	2.495	43.464	1.613	43.695
0.2	1000	0.1	10	2.531	43.906	1.595	43.312
0.2	1000	0.1	13	2.530	43.879	1.591	43.250
0.2	1000	0.1	90	2.434	43.164	1.636	44.449
0.2	1000	0.1	100	2.427	43.133	1.644	44.619
0.2	10000	0.004	5	2.397	42.575	1.521	43.140
0.2	10000	0.004	6	2.397	42.565	1.520	43.088
0.2	10000	0.004	10	2.395	42.577	1.519	43.027
0.2	10000	0.004	13	2.395	42.584	1.519	42.971
0.2	10000	0.004	90	2.435	43.165	1.529	42.468
0.2	10000	0.004	100	2.440	43.230	1.528	42.436
0.2	10000	0.04	5	2.331	41.621	1.661	43.938
0.2	10000	0.04	6	2.331	41.582	1.647	43.814
0.2	10000	0.04	10	2.334	41.618	1.656	43.979
0.2	10000	0.04	13	2.353	41.690	1.639	43.320
0.2	10000	0.04	90	2.424	42.704	1.526	42.156
0.2	10000	0.04	100	2.411	42.603	1.540	42.348
0.2	10000	0.1	5	2.354	41.740	1.972	49.375
0.2	10000	0.1	6	2.359	41.756	1.805	46.319
0.2	10000	0.1	10	2.364	41.679	1.774	45.569
0.2	10000	0.1	13	2.360	41.630	1.829	47.395
0.2	10000	0.1	90	2.388	42.067	1.617	43.361
0.2	10000	0.1	100	2.350	41.848	1.847	47.718
0.4	1000	0.004	5	2.457	43.506	1.525	43.309
0.4	1000	0.004	6	2.455	43.475	1.523	43.226
0.4	1000	0.004	10	2.452	43.517	1.520	42.973
0.4	1000	0.004	13	2.455	43.576	1.531	43.116
0.4	1000	0.004	90	2.514	44.762	1.534	42.379
0.4	1000	0.004	100	2.514	44.778	1.525	42.228
0.4	1000	0.04	5	2.552	44.066	1.573	43.417
0.4	1000	0.04	6	2.560	44.165	1.559	43.294
0.4	1000	0.04	10	2.554	44.190	1.531	42.925
0.4	1000	0.04	13	2.543	44.133	1.531	42.826
0.4	1000	0.04	90	2.406	43.140	1.669	45.596
0.4	1000	0.04	100	2.425	43.425	1.733	46.709
0.4	1000	0.1	5	2.496	43.577	1.681	44.988
0.4	1000	0.1	6	2.500	43.610	1.677	44.873
0.4	1000	0.1	10	2.549	44.080	1.667	44.535
0.4	1000	0.1	13	2.579	44.215	1.641	44.147
0.4	1000	0.1	90	2.494	43.674	1.616	43.875
0.4	1000	0.1	100	2.468	43.497	1.611	43.848
0.4	10000	0.004	5	2.396	42.547	1.524	43.081
0.4	10000	0.004	6	2.396	42.544	1.523	43.038

0.4	10000	0.004	10	2.395	42.563	1.524	43.013
0.4	10000	0.004	13	2.395	42.572	1.524	42.957
0.4	10000	0.004	90	2.465	43.529	1.542	42.500
0.4	10000	0.004	100	2.471	43.600	1.542	42.494
0.4	10000	0.04	5	2.340	41.706	1.689	44.608
0.4	10000	0.04	6	2.336	41.609	1.655	44.164
0.4	10000	0.04	10	2.332	41.554	1.687	44.691
0.4	10000	0.04	13	2.350	41.573	1.730	44.904
0.4	10000	0.04	90	2.379	42.180	1.622	43.495
0.4	10000	0.04	100	2.369	42.082	1.651	43.946
0.4	10000	0.1	5	2.402	42.064	1.976	50.089
0.4	10000	0.1	6	2.409	42.140	1.875	48.424
0.4	10000	0.1	10	2.399	42.012	1.878	48.072
0.4	10000	0.1	13	2.387	41.805	2.047	51.543
0.4	10000	0.1	90	2.414	42.003	1.660	44.400
0.4	10000	0.1	100	2.424	42.250	1.676	44.440
0.2	1000	0.01	5	2.426	43.017	1.485	42.981

Resultados para el modelo híbrido (RNA):

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	2.415	42.582	1.553	43.667
0.2	1000	0.004	6	2.413	42.517	1.546	43.578
0.2	1000	0.004	10	2.398	42.393	1.529	43.394
0.2	1000	0.004	13	2.398	42.425	1.533	43.446
0.2	1000	0.004	90	2.404	42.815	1.492	42.291
0.2	1000	0.004	100	2.409	42.855	1.487	42.190
0.2	1000	0.04	5	2.386	41.947	1.722	45.587
0.2	1000	0.04	6	2.379	41.868	1.690	45.152
0.2	1000	0.04	10	2.397	41.961	1.654	44.574
0.2	1000	0.04	13	2.390	41.887	1.623	44.168
0.2	1000	0.04	90	2.315	41.607	1.781	46.520
0.2	1000	0.04	100	2.321	41.754	1.823	47.124
0.2	1000	0.1	5	2.384	41.956	1.668	44.703
0.2	1000	0.1	6	2.377	41.905	1.662	44.607
0.2	1000	0.1	10	2.406	42.107	1.675	44.820
0.2	1000	0.1	13	2.410	42.112	1.661	44.584
0.2	1000	0.1	90	2.353	41.841	1.663	44.776
0.2	1000	0.1	100	2.344	41.787	1.669	44.864
0.2	10000	0.004	5	2.284	40.718	1.598	43.539

0.2	10000	0.004	6	2.285	40.719	1.596	43.522
0.2	10000	0.004	10	2.285	40.730	1.589	43.440
0.2	10000	0.004	13	2.284	40.734	1.584	43.388
0.2	10000	0.004	90	2.314	41.149	1.520	42.602
0.2	10000	0.004	100	2.316	41.168	1.522	42.600
0.2	10000	0.04	5	2.239	39.829	1.735	45.130
0.2	10000	0.04	6	2.238	39.837	1.640	44.071
0.2	10000	0.04	10	2.246	39.977	1.725	44.921
0.2	10000	0.04	13	2.244	39.955	1.635	44.021
0.2	10000	0.04	90	2.298	40.739	1.570	43.014
0.2	10000	0.04	100	2.300	40.707	1.586	43.214
0.2	10000	0.1	5	2.264	40.030	1.907	47.397
0.2	10000	0.1	6	2.270	40.200	1.883	46.990
0.2	10000	0.1	10	2.259	40.069	1.918	47.456
0.2	10000	0.1	13	2.249	39.996	1.802	45.952
0.2	10000	0.1	90	2.261	39.988	1.745	44.915
0.2	10000	0.1	100	2.257	39.920	1.759	45.129
0.4	1000	0.004	5	2.397	42.262	1.546	43.563
0.4	1000	0.004	6	2.396	42.218	1.540	43.489
0.4	1000	0.004	10	2.387	42.145	1.518	43.288
0.4	1000	0.004	13	2.387	42.176	1.517	43.301
0.4	1000	0.004	90	2.429	43.034	1.475	42.023
0.4	1000	0.004	100	2.433	43.067	1.470	41.941
0.4	1000	0.04	5	2.411	42.143	1.711	45.434
0.4	1000	0.04	6	2.403	42.063	1.680	45.015
0.4	1000	0.04	10	2.424	42.201	1.661	44.669
0.4	1000	0.04	13	2.419	42.131	1.628	44.232
0.4	1000	0.04	90	2.311	41.566	1.724	45.880
0.4	1000	0.04	100	2.314	41.722	1.785	46.771
0.4	1000	0.1	5	2.412	42.147	1.748	45.547
0.4	1000	0.1	6	2.400	42.124	1.711	45.424
0.4	1000	0.1	10	2.430	42.310	1.698	44.828
0.4	1000	0.1	13	2.434	42.354	1.672	44.565
0.4	1000	0.1	90	2.399	42.170	1.677	44.985
0.4	1000	0.1	100	2.382	42.082	1.692	45.260
0.4	10000	0.004	5	2.282	40.691	1.596	43.508
0.4	10000	0.004	6	2.282	40.689	1.594	43.493
0.4	10000	0.004	10	2.283	40.702	1.589	43.428
0.4	10000	0.004	13	2.282	40.700	1.585	43.380
0.4	10000	0.004	90	2.327	41.258	1.519	42.546
0.4	10000	0.004	100	2.331	41.297	1.519	42.551
0.4	10000	0.04	5	2.243	39.789	1.721	44.878
0.4	10000	0.04	6	2.239	39.796	1.647	44.149
0.4	10000	0.04	10	2.240	39.856	1.729	44.935

0.4	10000	0.04	13	2.240	39.863	1.669	44.460
0.4	10000	0.04	90	2.288	40.463	1.645	43.850
0.4	10000	0.04	100	2.278	40.361	1.661	44.139
0.4	10000	0.1	5	2.292	40.180	1.999	48.853
0.4	10000	0.1	6	2.327	40.521	1.898	47.399
0.4	10000	0.1	10	2.287	40.191	2.009	48.877
0.4	10000	0.1	13	2.276	40.288	1.921	47.449
0.4	10000	0.1	90	2.281	40.058	1.754	45.001
0.4	10000	0.1	100	2.273	39.938	1.749	44.949

9.3.3 BHP Billiton Limited (BHP)

Resultados para la técnica RBFN:

Parámetros	Entrenamiento		Validación	
N funciones	MAPE	RMSE	MAPE	RMSE
2	2.114	98.685	1.669	75.704
3	1.907	89.020	1.542	73.353
4	1.836	85.785	1.385	67.143
5	1.843	85.801	1.402	67.095
7	1.816	84.572	1.406	68.041
9	1.759	81.758	1.458	69.041
10	1.809	83.976	1.561	72.929
12	1.766	81.735	1.614	75.128
14	1.727	80.775	1.467	70.006
16	1.774	81.713	1.599	74.775
18	1.713	79.017	1.519	72.340
20	1.748	79.700	1.566	73.926
25	1.664	77.320	1.554	73.463
30	1.630	74.873	1.757	82.364
35	1.576	72.744	1.703	79.667
40	1.545	70.138	1.977	93.051
45	1.561	72.883	1.530	73.892
50	1.453	65.414	1.512	72.445

Resultados para la técnica SVR:

Parámetros		Entrenamiento		Validación	
C	Grado	MAPE	RMSE	MAPE	RMSE
2^{-1}	1	1.861	87.328	1.427	66.886
2^1	1	1.829	86.271	1.403	65.853
2^3	1	1.818	85.963	1.397	65.746
2^5	1	1.817	86.071	1.389	65.817
2^7	1	1.817	86.195	1.395	65.605
275	1	1.816	85.976	1.389	65.846
2^9	1	1.817	86.113	1.392	65.909
2^{-1}	2	6.919	301.469	2.122	101.783
2^1	2	6.419	293.018	2.464	116.537
2^3	2	6.202	290.247	2.692	128.594
2^5	2	5.994	285.966	3.094	146.523
2^7	2	5.846	280.467	3.865	179.087
275	2	5.676	278.449	4.076	187.469
2^9	2	5.532	275.028	4.372	199.642

1	1	1.839	86.562	1.413	66.366
3	1	1.826	86.131	1.397	65.819
4	1	1.823	86.039	1.401	65.926
5	1	1.821	86.021	1.400	65.894
6	1	1.822	85.901	1.391	65.943
7	1	1.820	85.949	1.396	65.901
8	1	1.818	85.963	1.397	65.746
9	1	1.819	85.952	1.394	65.885
10	1	1.820	85.950	1.391	65.763
20	1	1.818	85.940	1.386	65.721
30	1	1.817	86.107	1.390	65.871
40	1	1.817	86.057	1.390	65.829
50	1	1.818	86.080	1.389	65.721
60	1	1.816	86.024	1.389	65.836
70	1	1.817	86.105	1.388	65.999
80	1	1.817	86.085	1.386	65.787
90	1	1.818	86.165	1.386	65.892
100	1	1.817	86.130	1.391	65.774

Resultados para la técnica RNA:

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	2.014	93.376	1.587	73.563
0.2	1000	0.004	6	2.006	92.746	1.561	72.509
0.2	1000	0.004	10	2.010	92.857	1.546	71.930
0.2	1000	0.004	13	1.996	92.190	1.525	70.941
0.2	1000	0.004	90	1.958	91.238	1.524	70.404
0.2	1000	0.004	100	1.955	91.082	1.519	70.197
0.2	1000	0.04	5	2.014	93.376	1.587	73.563
0.2	1000	0.04	6	1.885	88.415	1.487	69.025
0.2	1000	0.04	10	1.880	88.182	1.482	68.898
0.2	1000	0.04	13	1.885	88.461	1.492	69.315
0.2	1000	0.04	90	1.869	87.007	1.424	67.752
0.2	1000	0.04	100	1.876	87.115	1.416	67.981
0.2	1000	0.1	5	1.855	86.411	1.390	66.206
0.2	1000	0.1	6	1.870	87.077	1.390	65.805
0.2	1000	0.1	10	1.868	87.301	1.394	65.782
0.2	1000	0.1	13	1.870	87.615	1.410	66.193
0.2	1000	0.1	90	1.911	88.790	1.559	74.612
0.2	1000	0.1	100	1.927	89.459	1.588	75.710
0.2	10000	0.004	5	1.872	87.284	1.421	66.978

0.2	10000	0.004	6	1.865	87.054	1.416	66.946
0.2	10000	0.004	10	1.858	86.836	1.417	67.054
0.2	10000	0.004	13	1.855	86.705	1.417	67.027
0.2	10000	0.004	90	1.870	87.558	1.457	68.237
0.2	10000	0.004	100	1.872	87.660	1.459	68.278
0.2	10000	0.04	5	1.819	85.169	1.390	66.490
0.2	10000	0.04	6	1.820	85.334	1.387	66.268
0.2	10000	0.04	10	1.836	85.792	1.382	65.766
0.2	10000	0.04	13	1.844	86.118	1.385	65.629
0.2	10000	0.04	90	1.854	87.180	1.399	65.926
0.2	10000	0.04	100	1.849	86.969	1.397	65.974
0.2	10000	0.1	5	1.838	86.037	1.385	66.136
0.2	10000	0.1	6	1.838	86.067	1.384	65.654
0.2	10000	0.1	10	1.845	86.494	1.386	65.788
0.2	10000	0.1	13	1.845	86.509	1.386	65.760
0.2	10000	0.1	90	1.845	86.649	1.390	65.980
0.2	10000	0.1	100	1.829	85.872	1.400	66.733
0.4	1000	0.004	5	1.980	91.886	1.540	71.963
0.4	1000	0.004	6	1.974	91.353	1.523	71.198
0.4	1000	0.004	10	1.970	91.133	1.511	70.756
0.4	1000	0.004	13	1.957	90.505	1.497	70.003
0.4	1000	0.004	90	1.929	89.855	1.494	69.555
0.4	1000	0.004	100	1.927	89.751	1.490	69.384
0.4	1000	0.04	5	1.878	87.652	1.410	66.042
0.4	1000	0.04	6	1.882	88.262	1.453	67.553
0.4	1000	0.04	10	1.877	88.080	1.457	67.788
0.4	1000	0.04	13	1.884	88.564	1.480	68.730
0.4	1000	0.04	90	1.874	87.087	1.417	67.952
0.4	1000	0.04	100	1.929	89.055	1.454	70.295
0.4	1000	0.1	5	1.839	86.259	1.396	67.052
0.4	1000	0.1	6	1.843	86.349	1.390	66.426
0.4	1000	0.1	10	1.855	86.790	1.388	65.979
0.4	1000	0.1	13	1.861	87.184	1.393	65.830
0.4	1000	0.1	90	1.838	85.961	1.405	67.463
0.4	1000	0.1	100	1.841	85.968	1.409	67.687
0.4	10000	0.004	5	1.868	87.091	1.416	66.652
0.4	10000	0.004	6	1.861	86.893	1.414	66.667
0.4	10000	0.004	10	1.852	86.620	1.414	66.758
0.4	10000	0.004	13	1.848	86.507	1.414	66.737
0.4	10000	0.004	90	1.873	87.814	1.463	68.182
0.4	10000	0.004	100	1.874	87.866	1.463	68.166
0.4	10000	0.04	5	1.827	85.478	1.388	66.261
0.4	10000	0.04	6	1.827	85.557	1.388	66.154
0.4	10000	0.04	10	1.831	85.824	1.385	65.899

0.4	10000	0.04	13	1.835	86.092	1.385	65.786
0.4	10000	0.04	90	1.853	87.433	1.392	65.849
0.4	10000	0.04	100	1.856	87.511	1.398	66.144
0.4	10000	0.1	5	1.842	86.262	1.391	66.552
0.4	10000	0.1	6	1.837	85.919	1.385	65.698
0.4	10000	0.1	10	1.853	86.957	1.393	66.127
0.4	10000	0.1	13	1.849	86.715	1.385	65.720
0.4	10000	0.1	90	1.823	85.572	1.397	66.802
0.4	10000	0.1	100	1.823	85.533	1.399	66.882

Resultados para el modelo híbrido (RNA):

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	1.949	90.495	1.518	71.005
0.2	1000	0.004	6	1.955	90.865	1.527	71.425
0.2	1000	0.004	10	1.932	89.553	1.476	69.546
0.2	1000	0.004	13	1.917	88.940	1.457	68.680
0.2	1000	0.004	90	1.880	87.821	1.461	68.378
0.2	1000	0.004	100	1.880	87.867	1.461	68.325
0.2	1000	0.04	5	1.877	87.566	1.465	68.473
0.2	1000	0.04	6	1.872	87.312	1.453	67.992
0.2	1000	0.04	10	1.864	87.098	1.454	68.196
0.2	1000	0.04	13	1.864	87.187	1.459	68.376
0.2	1000	0.04	90	1.845	85.772	1.393	67.069
0.2	1000	0.04	100	1.853	85.886	1.393	67.248
0.2	1000	0.1	5	1.856	86.325	1.381	65.899
0.2	1000	0.1	6	1.858	86.409	1.381	65.832
0.2	1000	0.1	10	1.868	87.057	1.389	65.905
0.2	1000	0.1	13	1.868	87.248	1.405	66.406
0.2	1000	0.1	90	1.899	88.384	1.574	74.500
0.2	1000	0.1	100	1.880	87.490	1.538	73.152
0.2	10000	0.004	5	1.856	86.076	1.394	66.568
0.2	10000	0.004	6	1.853	85.982	1.390	66.447
0.2	10000	0.004	10	1.842	85.648	1.388	66.468
0.2	10000	0.004	13	1.837	85.485	1.387	66.475
0.2	10000	0.004	90	1.845	86.288	1.435	67.424
0.2	10000	0.004	100	1.847	86.395	1.439	67.526
0.2	10000	0.04	5	1.811	84.778	1.381	66.287
0.2	10000	0.04	6	1.811	84.823	1.379	66.203
0.2	10000	0.04	10	1.821	85.100	1.376	66.002
0.2	10000	0.04	13	1.837	85.540	1.383	65.928
0.2	10000	0.04	90	1.850	86.718	1.400	66.408

0.2	10000	0.04	100	1.849	86.628	1.399	66.419
0.2	10000	0.1	5	1.835	85.838	1.375	65.549
0.2	10000	0.1	6	1.835	85.853	1.375	65.498
0.2	10000	0.1	10	1.834	85.876	1.375	65.562
0.2	10000	0.1	13	1.837	86.066	1.375	65.595
0.2	10000	0.1	90	1.830	85.907	1.395	66.833
0.2	10000	0.1	100	1.831	85.981	1.393	66.675
0.4	1000	0.004	5	1.933	89.632	1.479	69.851
0.4	1000	0.004	6	1.935	89.801	1.484	70.057
0.4	1000	0.004	10	1.910	88.573	1.457	68.898
0.4	1000	0.004	13	1.893	87.948	1.447	68.240
0.4	1000	0.004	90	1.865	87.147	1.449	67.985
0.4	1000	0.004	100	1.865	87.112	1.446	67.848
0.4	1000	0.04	5	1.879	87.581	1.434	67.267
0.4	1000	0.04	6	1.873	87.266	1.420	66.778
0.4	1000	0.04	10	1.864	87.130	1.432	67.368
0.4	1000	0.04	13	1.864	87.249	1.444	67.800
0.4	1000	0.04	90	1.854	85.997	1.400	67.450
0.4	1000	0.04	100	1.921	88.525	1.466	70.323
0.4	1000	0.1	5	1.833	86.065	1.384	66.385
0.4	1000	0.1	6	1.830	85.963	1.384	66.335
0.4	1000	0.1	10	1.846	86.355	1.377	65.774
0.4	1000	0.1	13	1.857	86.850	1.383	65.724
0.4	1000	0.1	90	1.822	85.260	1.391	66.981
0.4	1000	0.1	100	1.827	85.635	1.394	66.930
0.4	10000	0.004	5	1.852	85.876	1.391	66.521
0.4	10000	0.004	6	1.849	85.772	1.387	66.417
0.4	10000	0.004	10	1.837	85.426	1.387	66.362
0.4	10000	0.004	13	1.832	85.272	1.388	66.322
0.4	10000	0.004	90	1.851	86.540	1.438	67.384
0.4	10000	0.004	100	1.851	86.580	1.438	67.415
0.4	10000	0.04	5	1.820	85.262	1.378	65.888
0.4	10000	0.04	6	1.820	85.225	1.378	65.859
0.4	10000	0.04	10	1.822	85.343	1.377	65.944
0.4	10000	0.04	13	1.823	85.483	1.376	65.861
0.4	10000	0.04	90	1.850	87.269	1.388	66.117
0.4	10000	0.04	100	1.851	87.274	1.387	66.031
0.4	10000	0.1	5	1.832	85.649	1.383	65.821
0.4	10000	0.1	6	1.833	85.706	1.383	65.758
0.4	10000	0.1	10	1.831	85.644	1.378	65.590
0.4	10000	0.1	13	1.833	85.794	1.375	65.510
0.4	10000	0.1	90	1.825	85.619	1.393	66.944
0.4	10000	0.1	100	1.830	85.765	1.400	67.261

9.3.4 Fortuna Silver Mines (FSM)

Resultados para la técnica RBFN:

Parámetros	Entrenamiento		Validación	
N funciones	MAPE	RMSE	MAPE	RMSE
2	3.420	22.520	2.854	20.219
3	3.225	21.423	2.734	19.372
4	3.147	21.085	2.726	19.053
5	3.110	20.461	2.740	19.350
6	3.102	20.350	2.739	19.172
7	3.059	19.432	2.747	19.531
8	3.004	18.940	2.847	20.612
9	2.998	18.813	2.853	20.157
10	2.936	18.605	3.036	21.317
12	2.884	17.457	2.904	20.669
14	2.865	17.189	3.137	22.119
16	2.836	16.903	3.011	21.266
18	2.734	16.194	2.927	20.422
20	2.716	16.001	3.931	29.346
25	2.611	14.929	3.442	24.957
30	2.539	15.495	3.785	28.029
35	2.378	13.391	3.742	27.882
40	2.182	12.599	5.354	35.930
45	2.048	11.678	4.823	33.312
50	1.974	10.831	5.522	36.920

Resultados para la técnica SVR:

Parámetros		Entrenamiento		Validación	
C	Grado	MAPE	RMSE	MAPE	RMSE
2^{-1}	1	3.189	21.585	2.517	18.428
2^1	1	3.167	21.493	2.540	18.442
2^3	1	3.164	21.500	2.575	18.612
2^5	1	3.166	21.519	2.582	18.637
2^7	1	3.166	21.494	2.587	18.655
275	1	3.163	21.481	2.568	18.512
2^9	1	3.166	21.504	2.577	18.575
2^{-1}	2	10.444	54.705	5.731	40.174
2^1	2	10.338	53.836	6.125	43.476
2^3	2	9.874	51.405	6.415	44.719
2^5	2	8.372	44.946	6.149	41.567
2^7	2	4.572	28.908	4.169	27.294

275	2	3.479	23.397	3.360	21.302
2⁹	2	3.185	21.732	2.959	19.669
1	1	3.170	21.507	2.532	18.415
3	1	3.165	21.495	2.546	18.486
4	1	3.165	21.473	2.550	18.490
5	1	3.164	21.477	2.561	18.529
6	1	3.163	21.476	2.563	18.509
7	1	3.165	21.510	2.575	18.625
8	1	3.164	21.500	2.575	18.612
9	1	3.163	21.463	2.562	18.523
10	1	3.163	21.473	2.564	18.516
20	1	3.165	21.479	2.572	18.592
30	1	3.166	21.490	2.589	18.670
40	1	3.164	21.489	2.578	18.610
50	1	3.164	21.521	2.560	18.537
60	1	3.164	21.474	2.575	18.587
70	1	3.165	21.502	2.578	18.640
80	1	3.166	21.478	2.582	18.653
90	1	3.167	21.501	2.588	18.674
100	1	3.166	21.492	2.581	18.651

Resultados para la técnica RNA:

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	3.272	21.813	2.662	19.607
0.2	1000	0.004	6	3.278	21.852	2.670	19.633
0.2	1000	0.004	10	3.277	21.822	2.665	19.516
0.2	1000	0.004	13	3.267	21.785	2.658	19.395
0.2	1000	0.004	90	3.266	21.899	2.587	18.828
0.2	1000	0.004	100	3.260	21.860	2.585	18.819
0.2	1000	0.04	5	3.487	22.192	2.731	19.860
0.2	1000	0.04	6	3.485	22.172	2.724	19.801
0.2	1000	0.04	10	3.440	22.098	2.695	19.563
0.2	1000	0.04	13	3.430	22.069	2.689	19.515
0.2	1000	0.04	90	3.490	24.037	3.308	22.756
0.2	1000	0.04	100	3.625	25.175	3.609	24.313
0.2	1000	0.1	5	3.276	21.684	2.848	20.559
0.2	1000	0.1	6	3.278	21.711	2.872	20.680
0.2	1000	0.1	10	3.367	21.999	2.857	20.600
0.2	1000	0.1	13	3.388	22.092	2.889	20.856
0.2	1000	0.1	90	3.462	22.880	3.257	22.738

0.2	1000	0.1	100	3.824	25.171	3.051	21.986
0.2	10000	0.004	5	3.198	21.290	2.693	19.335
0.2	10000	0.004	6	3.197	21.290	2.690	19.290
0.2	10000	0.004	10	3.195	21.322	2.680	19.159
0.2	10000	0.004	13	3.192	21.298	2.682	19.157
0.2	10000	0.004	90	3.210	21.378	2.594	18.572
0.2	10000	0.004	100	3.209	21.361	2.603	18.639
0.2	10000	0.04	5	3.153	20.620	2.761	18.946
0.2	10000	0.04	6	3.158	20.668	2.744	18.845
0.2	10000	0.04	10	3.152	20.565	2.740	18.986
0.2	10000	0.04	13	3.164	20.727	2.695	18.701
0.2	10000	0.04	90	3.232	21.543	2.787	19.711
0.2	10000	0.04	100	3.237	21.598	2.809	19.931
0.2	10000	0.1	5	3.194	20.696	2.837	19.290
0.2	10000	0.1	6	3.182	20.960	2.765	18.752
0.2	10000	0.1	10	3.132	20.192	2.734	19.062
0.2	10000	0.1	13	3.154	19.971	2.793	19.195
0.2	10000	0.1	90	3.221	20.388	2.915	19.575
0.2	10000	0.1	100	3.552	21.049	2.898	20.309
0.4	1000	0.004	5	3.248	21.678	2.666	19.542
0.4	1000	0.004	6	3.252	21.707	2.666	19.543
0.4	1000	0.004	10	3.247	21.679	2.658	19.424
0.4	1000	0.004	13	3.239	21.651	2.646	19.301
0.4	1000	0.004	90	3.251	21.786	2.598	18.829
0.4	1000	0.004	100	3.246	21.755	2.598	18.838
0.4	1000	0.04	5	3.453	22.081	2.771	20.102
0.4	1000	0.04	6	3.450	22.067	2.765	20.035
0.4	1000	0.04	10	3.464	22.144	2.754	19.929
0.4	1000	0.04	13	3.450	22.126	2.760	19.972
0.4	1000	0.04	90	3.631	23.851	3.142	22.244
0.4	1000	0.04	100	3.621	23.977	3.170	22.489
0.4	1000	0.1	5	3.279	21.898	2.878	20.587
0.4	1000	0.1	6	3.279	21.915	2.900	20.735
0.4	1000	0.1	10	3.315	22.058	2.911	20.947
0.4	1000	0.1	13	3.331	22.102	2.924	21.097
0.4	1000	0.1	90	3.486	22.766	3.221	22.869
0.4	1000	0.1	100	4.001	26.038	3.109	22.482
0.4	10000	0.004	5	3.206	21.256	2.713	19.548
0.4	10000	0.004	6	3.206	21.254	2.707	19.454
0.4	10000	0.004	10	3.200	21.342	2.684	19.221
0.4	10000	0.004	13	3.196	21.304	2.684	19.222
0.4	10000	0.004	90	3.222	21.382	2.610	18.722
0.4	10000	0.004	100	3.219	21.363	2.620	18.797
0.4	10000	0.04	5	3.146	20.515	2.779	19.035

0.4	10000	0.04	6	3.156	20.604	2.768	18.957
0.4	10000	0.04	10	3.135	20.336	2.767	19.125
0.4	10000	0.04	13	3.156	20.606	2.751	18.910
0.4	10000	0.04	90	3.217	21.324	2.756	19.561
0.4	10000	0.04	100	3.204	21.336	2.820	19.692
0.4	10000	0.1	5	3.224	20.989	2.758	18.906
0.4	10000	0.1	6	3.208	21.128	2.763	18.834
0.4	10000	0.1	10	3.171	19.926	2.791	19.479
0.4	10000	0.1	13	3.174	19.834	2.785	19.201
0.4	10000	0.1	90	3.227	20.252	2.877	19.793
0.4	10000	0.1	100	3.693	21.502	2.887	21.001
0.2	1000	0.004	65	0.033	0.219	0.026	0.188

Resultados para el modelo híbrido (RNA):

Parámetros				Entrenamiento		Validación	
Momentum	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	3.284	21.773	2.710	19.803
0.2	1000	0.004	6	3.229	21.497	2.684	19.499
0.2	1000	0.004	10	3.221	21.485	2.661	19.356
0.2	1000	0.004	13	3.216	21.459	2.651	19.277
0.2	1000	0.004	90	3.206	21.497	2.567	18.684
0.2	1000	0.004	100	3.202	21.476	2.578	18.698
0.2	1000	0.04	5	3.510	22.194	2.760	19.976
0.2	1000	0.04	6	3.506	22.188	2.766	20.014
0.2	1000	0.04	10	3.434	21.971	2.736	19.747
0.2	1000	0.04	13	3.426	21.963	2.732	19.706
0.2	1000	0.04	90	3.593	25.222	3.662	24.627
0.2	1000	0.04	100	3.802	26.883	4.039	26.626
0.2	1000	0.1	5	3.300	21.763	2.854	20.410
0.2	1000	0.1	6	3.390	22.033	2.806	20.007
0.2	1000	0.1	10	3.426	22.078	2.807	20.050
0.2	1000	0.1	13	3.442	22.133	2.819	20.090
0.2	1000	0.1	90	3.424	22.834	3.264	22.609
0.2	1000	0.1	100	3.762	25.178	3.020	21.748
0.2	10000	0.004	5	3.156	21.054	2.724	19.393
0.2	10000	0.004	6	3.152	21.034	2.726	19.385
0.2	10000	0.004	10	3.145	20.996	2.724	19.324
0.2	10000	0.004	13	3.144	20.988	2.723	19.303
0.2	10000	0.004	90	3.149	21.022	2.658	18.790
0.2	10000	0.004	100	3.148	21.022	2.661	18.794
0.2	10000	0.04	5	3.155	20.777	2.762	19.079

0.2	10000	0.04	6	3.145	20.804	2.808	19.809
0.2	10000	0.04	10	3.180	20.976	2.805	20.018
0.2	10000	0.04	13	3.197	21.077	2.800	19.953
0.2	10000	0.04	90	3.251	21.781	3.004	21.607
0.2	10000	0.04	100	3.263	21.754	3.103	22.145
0.2	10000	0.1	5	3.186	21.275	2.893	20.292
0.2	10000	0.1	6	3.148	20.627	2.737	19.461
0.2	10000	0.1	10	3.181	20.237	2.770	19.558
0.2	10000	0.1	13	3.151	20.449	2.771	19.560
0.2	10000	0.1	90	3.172	20.998	2.754	19.349
0.2	10000	0.1	100	3.665	21.837	2.988	21.230
0.4	1000	0.004	5	3.239	21.572	2.709	19.669
0.4	1000	0.004	6	3.208	21.402	2.693	19.467
0.4	1000	0.004	10	3.204	21.395	2.669	19.329
0.4	1000	0.004	13	3.199	21.373	2.654	19.238
0.4	1000	0.004	90	3.197	21.437	2.589	18.738
0.4	1000	0.004	100	3.191	21.406	2.601	18.755
0.4	1000	0.04	5	3.454	22.068	2.834	20.305
0.4	1000	0.04	6	3.474	22.144	2.827	20.316
0.4	1000	0.04	10	3.434	22.026	2.800	20.102
0.4	1000	0.04	13	3.431	22.033	2.793	20.047
0.4	1000	0.04	90	3.642	24.097	3.200	22.486
0.4	1000	0.04	100	3.638	24.426	3.282	23.041
0.4	1000	0.1	5	3.286	21.953	2.891	20.581
0.4	1000	0.1	6	3.348	22.187	2.876	20.474
0.4	1000	0.1	10	3.387	22.258	2.879	20.596
0.4	1000	0.1	13	3.424	22.331	2.864	20.488
0.4	1000	0.1	90	4.081	26.600	3.074	22.116
0.4	1000	0.1	100	3.437	22.861	3.172	22.403
0.4	10000	0.004	5	3.168	21.102	2.730	19.454
0.4	10000	0.004	6	3.163	21.080	2.732	19.452
0.4	10000	0.004	10	3.152	21.026	2.728	19.373
0.4	10000	0.004	13	3.151	21.020	2.723	19.328
0.4	10000	0.004	90	3.161	21.052	2.666	18.887
0.4	10000	0.004	100	3.159	21.051	2.669	18.901
0.4	10000	0.04	5	3.162	20.701	2.773	19.065
0.4	10000	0.04	6	3.133	20.498	2.793	19.649
0.4	10000	0.04	10	3.155	20.710	2.849	20.203
0.4	10000	0.04	13	3.177	20.973	2.788	19.833
0.4	10000	0.04	90	3.252	21.704	2.848	20.559
0.4	10000	0.04	100	3.260	21.816	2.892	20.985
0.4	10000	0.1	5	3.212	21.626	2.949	20.696
0.4	10000	0.1	6	3.165	20.741	2.722	19.512
0.4	10000	0.1	10	3.165	20.074	2.835	20.190

0.4	10000	0.1	13	3.156	20.112	2.834	20.185
0.4	10000	0.1	90	3.330	21.320	2.713	19.173
0.4	10000	0.1	100	3.251	20.235	2.871	19.460

9.3.5 Southern Copper (SCCO):

Resultados para la técnica RBFN:

Parámetros	Entrenamiento		Validación	
N funciones	MAPE	RMSE	MAPE	RMSE
2	1.532	57.908	1.014	49.114
3	1.482	56.133	3.622	147.403
4	1.455	54.873	2.016	83.329
5	1.429	53.959	2.940	118.504
6	1.396	53.251	3.170	128.694
7	1.370	52.283	3.007	121.388
8	1.375	52.458	3.255	131.852
9	1.320	51.217	3.207	129.477
10	1.346	49.813	3.354	135.955
12	1.320	50.647	3.053	124.962
14	1.255	46.422	4.176	163.982
16	1.228	45.389	3.681	146.782
18	1.212	45.218	4.230	168.973
20	1.149	42.134	3.770	152.109
25	1.135	42.189	2.297	94.342
30	1.063	38.872	1.362	62.169
35	1.014	38.020	2.172	91.780
40	0.959	35.790	2.316	97.533
45	0.888	32.587	1.646	74.684
50	0.818	30.485	3.597	146.525

Resultados para la técnica SVR:

Parámetros		Entrenamiento		Validación	
C	Grado	MAPE	RMSE	MAPE	RMSE
2^{-1}	1	1.486	56.966	1.031	49.437
2^1	1	1.471	56.499	1.047	49.705
2^3	1	1.469	56.480	1.062	50.404
2^5	1	1.470	56.512	1.062	50.413
2^7	1	1.469	56.499	1.060	50.425
275	1	1.469	56.544	1.066	50.611
2^9	1	1.470	56.581	1.064	50.563

2^{-1}	2	2.125	86.515	5.511	225.193
2^1	2	2.054	82.621	5.091	209.429
2^3	2	1.926	76.602	4.155	175.585
2^5	2	1.691	66.947	2.979	127.493
2^7	2	1.460	57.328	1.433	66.314
275	2	1.409	55.654	1.270	59.093
2^9	2	1.383	55.102	1.231	57.457
1	1	1.477	56.657	1.039	49.654
3	1	1.470	56.477	1.054	49.815
4	1	1.470	56.496	1.053	49.813
5	1	1.469	56.479	1.057	49.979
6	1	1.469	56.486	1.059	49.962
7	1	1.470	56.491	1.055	50.195
8	1	1.469	56.480	1.062	50.404
9	1	1.468	56.512	1.063	50.433
10	1	1.469	56.502	1.059	50.329
20	1	1.469	56.547	1.064	50.490
30	1	1.469	56.546	1.061	50.529
40	1	1.468	56.526	1.061	50.360
50	1	1.468	56.560	1.061	50.557
60	1	1.469	56.525	1.063	50.509
70	1	1.469	56.523	1.061	50.435
80	1	1.469	56.523	1.064	50.667
90	1	1.469	56.583	1.066	50.895
100	1	1.469	56.557	1.060	50.496

Resultados para la técnica RNA:

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	1.502	56.818	1.019	49.219
0.2	1000	0.004	6	1.506	56.954	1.008	48.820
0.2	1000	0.004	10	1.503	56.904	1.014	49.131
0.2	1000	0.004	13	1.502	56.906	1.009	48.679
0.2	1000	0.004	90	1.504	57.541	1.035	48.983
0.2	1000	0.004	100	1.504	57.555	1.035	48.937
0.2	1000	0.04	5	1.488	56.802	1.015	48.320
0.2	1000	0.04	6	1.482	56.570	1.029	48.756
0.2	1000	0.04	10	1.489	56.993	1.026	48.669
0.2	1000	0.04	13	1.494	57.206	1.028	48.611
0.2	1000	0.04	90	1.553	59.459	1.229	54.281
0.2	1000	0.04	100	1.558	59.599	1.262	55.468

0.2	1000	0.1	5	1.464	56.172	1.035	49.374
0.2	1000	0.1	6	1.462	56.126	1.030	49.731
0.2	1000	0.1	10	1.469	56.422	1.039	49.245
0.2	1000	0.1	13	1.473	56.572	1.052	49.413
0.2	1000	0.1	90	1.517	58.396	1.184	55.234
0.2	1000	0.1	100	1.516	58.346	1.183	55.818
0.2	10000	0.004	5	1.473	56.199	1.057	50.461
0.2	10000	0.004	6	1.474	56.208	1.054	50.342
0.2	10000	0.004	10	1.473	56.186	1.064	50.639
0.2	10000	0.004	13	1.473	56.191	1.065	50.685
0.2	10000	0.004	90	1.486	56.925	1.048	49.586
0.2	10000	0.004	100	1.486	56.980	1.053	49.808
0.2	10000	0.04	5	1.450	55.470	1.061	50.699
0.2	10000	0.04	6	1.450	55.567	1.082	51.378
0.2	10000	0.04	10	1.451	55.586	1.034	49.739
0.2	10000	0.04	13	1.452	55.622	1.038	49.820
0.2	10000	0.04	90	1.475	56.669	1.051	50.675
0.2	10000	0.04	100	1.479	56.804	1.069	51.545
0.2	10000	0.1	5	1.436	54.568	2.528	102.161
0.2	10000	0.1	6	1.448	55.613	1.135	53.289
0.2	10000	0.1	10	1.422	54.206	3.291	133.683
0.2	10000	0.1	13	1.441	54.804	2.092	86.722
0.2	10000	0.1	90	1.431	54.547	4.567	179.405
0.2	10000	0.1	100	1.462	56.042	1.042	49.408
0.4	1000	0.004	5	1.496	56.619	1.022	49.321
0.4	1000	0.004	6	1.499	56.711	1.017	49.054
0.4	1000	0.004	10	1.495	56.679	1.019	49.271
0.4	1000	0.004	13	1.495	56.692	1.012	48.830
0.4	1000	0.004	90	1.503	57.514	1.036	48.970
0.4	1000	0.004	100	1.502	57.486	1.034	48.909
0.4	1000	0.04	5	1.483	56.646	1.021	48.309
0.4	1000	0.04	6	1.474	56.359	1.033	48.807
0.4	1000	0.04	10	1.486	56.885	1.029	48.561
0.4	1000	0.04	13	1.492	57.124	1.037	48.656
0.4	1000	0.04	90	1.557	59.721	1.354	58.671
0.4	1000	0.04	100	1.563	59.920	1.394	60.038
0.4	1000	0.1	5	1.464	56.196	1.025	49.441
0.4	1000	0.1	6	1.462	56.071	1.074	51.349
0.4	1000	0.1	10	1.467	56.327	1.021	49.106
0.4	1000	0.1	13	1.468	56.380	1.020	49.048
0.4	1000	0.1	90	1.489	57.275	1.041	50.673
0.4	1000	0.1	100	1.492	57.376	1.041	51.146
0.4	10000	0.004	5	1.471	56.184	1.057	50.549
0.4	10000	0.004	6	1.472	56.188	1.055	50.463

0.4	10000	0.004	10	1.471	56.177	1.064	50.723
0.4	10000	0.004	13	1.471	56.186	1.066	50.796
0.4	10000	0.004	90	1.491	57.146	1.053	49.666
0.4	10000	0.004	100	1.490	57.151	1.057	49.850
0.4	10000	0.04	5	1.451	55.453	1.047	50.224
0.4	10000	0.04	6	1.447	55.525	1.114	52.545
0.4	10000	0.04	10	1.453	55.622	1.036	49.696
0.4	10000	0.04	13	1.452	55.622	1.051	50.231
0.4	10000	0.04	90	1.462	56.011	1.110	52.757
0.4	10000	0.04	100	1.468	56.233	1.035	49.693
0.4	10000	0.1	5	1.431	54.473	2.917	116.206
0.4	10000	0.1	6	1.442	55.303	1.423	64.610
0.4	10000	0.1	10	1.413	53.805	3.817	154.119
0.4	10000	0.1	13	1.443	55.363	1.076	52.828
0.4	10000	0.1	90	1.432	54.688	1.743	76.421
0.4	10000	0.1	100	1.443	55.038	4.820	191.045
0.1	1000	0.004	6	0.015	0.571	0.010	0.487

Resultados para el modelo híbrido (RNA):

Momentum	Parámetros			Entrenamiento		Validación	
	Épocas	Tasa aprendizaje	Nro. neuronas	MAPE	RMSE	MAPE	RMSE
0.2	1000	0.004	5	1.509	57.083	1.001	48.333
0.2	1000	0.004	6	1.503	56.877	1.006	48.631
0.2	1000	0.004	10	1.501	56.861	1.004	48.557
0.2	1000	0.004	13	1.500	56.820	0.998	48.319
0.2	1000	0.004	90	1.506	57.463	1.008	48.314
0.2	1000	0.004	100	1.505	57.473	1.011	48.309
0.2	1000	0.04	5	1.478	56.435	1.033	48.818
0.2	1000	0.04	6	1.484	56.670	1.032	48.679
0.2	1000	0.04	10	1.488	56.932	1.030	48.658
0.2	1000	0.04	13	1.491	57.098	1.034	48.737
0.2	1000	0.04	90	1.555	59.572	1.296	56.413
0.2	1000	0.04	100	1.561	59.756	1.333	57.809
0.2	1000	0.1	5	1.463	56.038	1.074	51.583
0.2	1000	0.1	6	1.466	56.256	1.031	49.367
0.2	1000	0.1	10	1.470	56.452	1.037	49.133
0.2	1000	0.1	13	1.475	56.644	1.045	49.209
0.2	1000	0.1	90	1.525	58.633	1.240	56.682
0.2	1000	0.1	100	1.523	58.505	1.183	55.122
0.2	10000	0.004	5	1.472	56.181	1.065	50.785
0.2	10000	0.004	6	1.471	56.179	1.063	50.701

0.2	10000	0.004	10	1.473	56.188	1.058	50.395
0.2	10000	0.004	13	1.473	56.192	1.057	50.353
0.2	10000	0.004	90	1.491	57.037	1.035	48.948
0.2	10000	0.004	100	1.493	57.136	1.034	48.847
0.2	10000	0.04	5	1.449	55.489	1.117	52.594
0.2	10000	0.04	6	1.450	55.506	1.077	51.398
0.2	10000	0.04	10	1.451	55.584	1.052	50.334
0.2	10000	0.04	13	1.452	55.604	1.044	50.045
0.2	10000	0.04	90	1.472	56.605	1.026	50.163
0.2	10000	0.04	100	1.474	56.689	1.035	50.597
0.2	10000	0.1	5	1.452	55.601	1.136	53.570
0.2	10000	0.1	6	1.440	54.691	2.400	97.945
0.2	10000	0.1	10	1.436	54.568	3.255	130.583
0.2	10000	0.1	13	1.435	54.506	3.445	138.078
0.2	10000	0.1	90	1.447	55.326	1.031	50.400
0.2	10000	0.1	100	1.442	55.093	4.053	160.495
0.4	1000	0.004	5	1.502	56.826	1.003	48.456
0.4	1000	0.004	6	1.499	56.724	1.008	48.677
0.4	1000	0.004	10	1.497	56.709	1.005	48.616
0.4	1000	0.004	13	1.495	56.694	1.001	48.386
0.4	1000	0.004	90	1.509	57.583	1.008	48.296
0.4	1000	0.004	100	1.507	57.563	1.011	48.292
0.4	1000	0.04	5	1.470	56.248	1.030	48.911
0.4	1000	0.04	6	1.497	56.683	1.008	48.708
0.4	1000	0.04	10	1.485	56.846	1.033	48.632
0.4	1000	0.04	13	1.489	57.028	1.038	48.754
0.4	1000	0.04	90	1.561	59.882	1.421	60.851
0.4	1000	0.04	100	1.575	60.327	1.465	62.520
0.4	1000	0.1	5	1.463	56.061	1.110	52.727
0.4	1000	0.1	6	1.467	56.215	1.029	49.811
0.4	1000	0.1	10	1.469	56.329	1.018	49.205
0.4	1000	0.1	13	1.470	56.391	1.015	49.154
0.4	1000	0.1	90	1.491	57.311	1.047	51.118
0.4	1000	0.1	100	1.496	57.448	1.048	51.279
0.4	10000	0.004	5	1.470	56.157	1.069	51.029
0.4	10000	0.004	6	1.470	56.163	1.066	50.884
0.4	10000	0.004	10	1.471	56.174	1.063	50.702
0.4	10000	0.004	13	1.471	56.185	1.062	50.660
0.4	10000	0.004	90	1.496	57.254	1.042	49.190
0.4	10000	0.004	100	1.498	57.342	1.040	49.057
0.4	10000	0.04	5	1.448	55.493	1.143	53.630
0.4	10000	0.04	6	1.449	55.459	1.092	52.245
0.4	10000	0.04	10	1.450	55.563	1.063	50.758
0.4	10000	0.04	13	1.451	55.559	1.063	50.871

0.4	10000	0.04	90	1.458	55.982	1.098	52.064
0.4	10000	0.04	100	1.459	56.050	1.063	50.638
0.4	10000	0.1	5	1.454	55.573	1.130	53.287
0.4	10000	0.1	6	1.452	55.489	1.121	53.555
0.4	10000	0.1	10	1.440	55.167	1.154	56.581
0.4	10000	0.1	13	1.437	55.055	1.201	59.035
0.4	10000	0.1	90	1.429	54.559	1.905	81.935
0.4	10000	0.1	100	1.453	55.651	1.174	55.556